

**UNIVERSIDADE FEDERAL DO PARANÁ**

**SILVIO DA COSTA REIS**

**ESTUDO DE META-HEURÍSTICA PARA ALOCAÇÃO DE  
CONTROLADORES FACTS**

**CURITIBA**

**2017**

SILVIO DA COSTA REIS

ESTUDO DE META-HEURÍSTICAS PARA ALOCAÇÃO DE  
CONTROLADORES FACTS

Dissertação apresentada como requisito parcial  
para a obtenção do grau de Mestre no Programa  
de Pós-Graduação em Engenharia Elétrica,  
Setor de Tecnologia da Universidade Federal do  
Paraná – UFPR.

Orientador: Prof. Dr. Odilon Luís Tortelli

Coorientador: Prof. Dr. Leandro dos Santos  
Coelho

Curitiba

2017

---

R375e Reis, Silvio da Costa  
Estudo de meta-heurísticas para alocação de controladores FACTS /  
Silvio da Costa Reis. – Curitiba, 2017.  
127f. : il. [algumas color.] ; 30 cm.

Dissertação (mestrado) - Universidade Federal do Paraná, Setor de  
Tecnologia, Programa de Pós-graduação em Engenharia Elétrica, 2017.

Orientador: Odilon Luís Tortelli -- Coorientador: Leandro dos Santos  
Coelho.

Bibliografia: p. 109-113.

1. Energia elétrica - Planejamento. 2. Meta-heurísticas. I. Universidade  
Federal do Paraná. II. Tortelli, Odilon Luís. III. Coelho, Leonardo dos  
Santos IV. Título.

CDD: 333.7932

---



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
Setor TECNOLOGIA  
Programa de Pós-Graduação ENGENHARIA ELÉTRICA

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **SILVIO DA COSTA REIS** intitulada: **Estudo de Meta-heurísticas para Alocação de Controladores FACTS** após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 03 de Agosto de 2017.



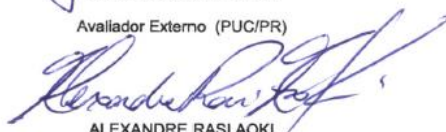
ODILON LUIS TORTELLI

Presidente da Banca Examinadora (UFPR)



JULIO CÉSAR NIEVOLA

Avaliador Externo (PUC/PR)



ALEXANDRE RASI AOKI

Avaliador Interno (UFPR)



LEANDRO DOS SANTOS COELHO

Avaliador Interno (UFPR)



GIDEON VILLAR LEANDRO

Avaliador Interno (UFPR)

## Resumo

As empresas do setor elétrico estão sujeitas a constantes desafios para proporcionar energia elétrica de forma eficiente e segura para os consumidores, tendo em vista que a insegurança ou ineficiência no fornecimento é fonte de prejuízos diversos tanto para os consumidores residenciais, como, principalmente, para os comerciais e industriais. Assim, portanto, é de suma importância a superação contínua destes desafios por parte dos agentes do setor. Países como o Brasil, com grande extensão territorial e distribuição populacional pouco homogênea, estão mais sujeitos aos desafios de expandir e operar uma rede elétrica interligada de maior porte que conecta os centros de geração aos centros de consumo. Nesse contexto os Controladores FACTS (do inglês, *Flexible Alternate Current Transmission System*) tem papel extremamente relevante. Dessa forma, a correta localização destes dispositivos na rede elétrica pode propiciar grandes vantagens operacionais, aumentando a controlabilidade do sistema, com reflexos na melhoria da sua eficiência e segurança. Tendo isto em vista esta dissertação visa o estudo, implementação e comparação de seis metodologias de alocação de dispositivos FACTS baseadas em meta-heurísticas. Foram considerados para tanto os controladores denominados da segunda geração: *Static Synchronous Compensator* (STATCOM), *Static Synchronous Series Compensator* (SSSC) e *Unified Power Flow Controller* (UPFC). A alocação destes dispositivos é considerada tanto de forma individual como simultânea, por meio do cálculo de fluxo de potência, sendo este baseado no método de Newton-Raphson, que incorpora a representação funcional de cada um dos controladores. A técnica de Algoritmos Genéticos (AG) é utilizada como base para a implementação das demais meta-heurísticas de otimização, tanto como aferição dos resultados quanto como base de comparação, visto que ela já foi largamente utilizada para o propósito de alocação de dispositivos em redes elétricas. Para a comparação e validação destes métodos foram utilizados principalmente dois sistemas teste, um de pequeno porte e um de porte médio, sendo que no sistema de pequeno porte foram considerados diferentes níveis de carga. Os resultados obtidos apontaram que, embora as diferentes técnicas tenham demonstrado potencialidade para lidar com problemas complexos e proporcionar soluções adequadas para alocação de controladores FACTS, a técnica GWO (Grey Wolf Optimizer) apresentou um desempenho particularmente mais destacado, que aliado a maior simplicidade na definição dos parâmetros de atuação a qualificam como alternativa relevante à consagrada técnica de AG para estudos dessa natureza. A avaliação do desempenho das técnicas meta-heurísticas de desenvolvimento recente tratadas neste trabalho impactam diretamente a pesquisa de alocação de sistemas reais, permitindo o aperfeiçoamento de metodologias e a redução do custo computacional.

Palavra chave: Planejamento de Operação, Dispositivos FACTS , Alocação de controladores, Meta-heurísticas de otimização.

## **Abstract**

Companies in the electricity sector are faced with constant challenges to provide electricity in an efficient and safe way for consumers, since insecurity or inefficiency in supply is a source of diverse damages for both residential consumers and especially, Commercial and industrial consumers. Therefore, it is extremely important to continuously overcome these challenges on the part of the agents of the sector. Countries such as Brazil, with a large territorial extension and poor homogeneous population distribution, are more subject to the challenges of expanding and operating a larger interconnected power grid that connects generation centers to consumption centers. In this context, the FACTS (Flexible Alternate Current Transmission System) Controllers play extremely relevant roles. In this way, the correct location of these devices in the electrical network can provide great operational advantages, increasing the controllability of the system, with reflexes in the improvement of its efficiency and safety. With this in mind, this dissertation aims to study, implement and compare six methodologies based on metaheuristics to allocate FACTS devices. Static Synchronous Compensator (STATCOM), Static Synchronous Series Compensator (SSSC) and Unified Power Flow Controller (UPFC) were considered for this purpose. The allocation of these devices is considered both individually and simultaneously, by means of the power flow calculation, which is based on the Newton-Raphson method, which incorporates the functional representation of each of the controllers. The Genetic Algorithm (GA) technique is used as the basis for the implementation of other optimization meta-heuristics, since it has already been widely used for the purpose of device allocation in power networks. For the comparison and validation of these methods, two test systems were used, one of small size and one of medium size. Different load levels were considered with the small test system simulations. The performance evaluation of the recent development meta-heuristic techniques, treated in this work, directly impact the research of allocation of real systems, allowing the improvement of methodologies and the reduction of computational cost. The results showed that, although the different techniques have demonstrated potential to deal with complex problems and provide adequate solutions for FACTS controller allocation, the GWO (Grey Wolf Optimizer) technique presented a particularly outstanding performance, which, together with the simplicity of parameters definition qualify it as a relevant alternative to the established AG technique for studies of this nature. The evaluation of the performance of the meta-heuristic techniques of recent development treated in this work directly impact the research of allocation of real systems, allowing the improvement of methodologies and the reduction of computational cost.

**Keyword:** Transmission Systems Planning, FACTS devices, Controllers allocation, Meta-heuristics.

## Lista de Figuras

Figura 2.1: Primeira Geração de Controladores FACTS - Estrutura Básica.....	24
Figura 2.2: Estrutura típica e representação equivalente do Conversor tipo VSC.....	26
Figura 2.3: Estrutura básica do STATCOM.....	27
Figura 2.4: Representação equivalente do Conversor STATCOM.....	27
Figura 2.5: Diagramas Fasoriais dos modos de operação do STATCOM.....	28
Figura 2.6: Esquema do SSSC.....	29
Figura 2.7: Circuito equivalente ao esquema do SSSC.....	30
Figura 2.8: Diagrama do UPFC.....	31
Figura 2.9: Modos de Operação do UPFC - Diagramas fasoriais.....	32
Figura 3.1: Diagrama dos passos mais importantes do GA.....	38
Figura 3.2: Fluxograma do algoritmo CROW.....	40
Figura 3.3: Fluxograma algoritmo SSO.....	42
Figura 3.4: Fluxograma do algoritmo ORCS.....	45
Figura 3.5: Exemplo de ações das alcatéias.....	47
Figura 3.6: pirâmide hierárquica das alcatéias.....	47
Figura 3.7: Reprodução em 2D e 3D da técnica de ataque a presa.....	49
Figura 3.8: Adaptação e tradução do fluxograma do algoritmo GWO.....	50
Figura 3.9: Exemplos de comportamento do <i>Dragonfly</i> .....	50
Figura 3.10: Adaptação e tradução do fluxograma do algoritmo <i>Dragonfly</i> .....	54
Figura 3.11: Fluxograma comum entre os algoritmos.....	55
Figura 4.1: Exemplo da representação de patamares.....	62

Figura 4.2: Representação mais simples da movimentação dos dados.....	63
Figura 4.3: Exemplo de codificação.....	66
Figura 4.4: Fluxograma do programa principal/inicial.....	67
Figura 4.5: Fluxograma genérico dos programa meta-heurísticas.....	68
Figura 4.6: Fluxograma da preparação dos dados e o cálculo do fluxo de potência.....	69
Figura 5.1: Exemplo de caso teste, o caso de 14 barras.....	71
Figura 5.2: Perdas ativas (em pu) (1) sem FACTS, (2) STATCOM, (3) SSSC e (4) UPFC.....	75
Figura 5.3: Função objetivo: melhora percentual média (a) STATCOM, (b) SSSC e (c) UPFC.....	75
Figura 5.4: Tempo médio de simulação para alocação de um único controlador (a) STATCOM, (b) SSSC, (c) UPFC .....	77
Figura 5.5: Melhores resultados em pu dos dispositivos (1) original, (2) STATCOM, (3) SSSC e (4) UPFC.....	79
Figura 5.6: Função objetivo: melhora percentual média (a) STATCOM, (b) SSSC,(c) UPFC.....	81
Figura 5.7: Tempo médio de simulação para alocação de um único controlador (a) STATCOM, (b) SSSC, (c) UPFC.....	82
Figura 5.8: Melhoria percentual média e desvio padrão para 14-1 com um de cada dispositivo.....	87
Figura 5.9: Perdas obtidas pelos algoritmos (1) SSO (2) ORCS (3) GWO (4) GA (5) DA (6) CROW.....	88
Figura 5.10: Número médio de gerações e desvio padrão.....	89
Figura 5.11: Desvio e tempo médio para 14 para um patamar em segundos.....	91
Figura 5.12: Melhora percentual média e desvio padrão para o sistema de 14 barras com 3 patamares de carga.....	94
Figura 5.13: Perdas obtidas pelos algoritmos (1)SSO (2) ORCS (3) GWO (4) GA (5) DA (6) CROW.....	95



Figura 5.14: Média e desvio padrão de gerações utilizadas 14 barras 3 patamares.....	96
Figura 5.15: Desvio e tempo médio para 14 barras 3 patamares .....	98
Figura 5.16: Melhoria percentual média para o sistema de 118 barras com dois FACTS .....	100
Figura 5.17: Perdas obtidas pelos algoritmos (1)SSO (2) ORCS (3) GWO (4) GA (5) DA (6) CROW.....	101
Figura 5.18: Média de gerações utilizadas 118 e desvio.....	102
Figura 5.19: Desvio e tempo médio para 118.....	103
Figura 5.20: Tempo médio utilizado para cada caso de estudo.....	105
Figura 5.21: Número médio de gerações utilizada para cada caso de estudo.....	105
Figura A.1: Melhoria percentual média para o sistema de 30 barras com um de cada dispositivo.....	116
Figura A.2: Perdas obtidas pelos algoritmos (1)SSO (2) ORCS (3) GWO (4) GA (5) DA (6) CROW.....	117
Figura A.3: Número médio de gerações e desvio padrão .....	119
Figura A.4: Desvio e tempo médio para 30 barras em segundos.....	120
Figura A.5: Melhoria percentual média para o sistema de 57 barras.....	123
Figura A.6: Perdas obtidas pelos algoritmos (1)SSO (2) ORCS (3) GWO (4) GA (5) DA (6) CROW.....	124
Figura A.7: Média e desvio padrão de gerações utilizadas 57 barras.....	125
Figura A.8: Desvio e tempo médio para 57.....	127

## Lista de Tabelas

Tabela 5.1: Alocação e frequência – Sistema teste 14 barras com um patamar de carga.....	74
Tabela 5.2: Alocação – Sistema teste de 118 barras.....	79
Tabela 5.3: Alocação – Sistema de 14 barras 1 patamar.....	86
Tabela 5.4: Melhor alocação – Sistema de 14 barras 1 patamar.....	89
Tabela 5.5: Alocação – Sistema de 14 barras com 3 patamares de carga.....	93
Tabela 5.6: Melhor alocação – Sistema de 14 barras 3 patamares.....	96
Tabela 5.7: Alocação – Sistema de 118 barras.....	99
Tabela 5.8: Melhor alocação – Sistema de 118 barras.....	101
Tabela 5.9: Influência dos controladores.....	106
Tabela A.1: Alocação – Sistema de 30 barras.....	115
Tabela A.2: Melhor alocação – Sistema de 30 barras.....	118
Tabela A.3: Alocação – Sistema de 57 barras.....	122
Tabela A.4: Melhor alocação – Sistema de 57 barras.....	124

## Lista de Siglas

<b>AC/CA</b>	Corrente Alternada
<b>DA</b>	<i>Dragonfly Algorithm</i>
<b>DC</b>	Corrente Contínua
<b>FACTS</b>	<i>Flexible AC Transmission System</i>
<b>GA/AG</b>	<i>Genetic Algorithm</i>
<b>GSA</b>	<i>Gravitational search algorithm</i>
<b>GTO</b>	<i>Gate Turn-off Thyristor</i>
<b>GWO</b>	<i>Grey Wolf optimizer</i>
<b>I.A.</b>	Inteligência Artificial
<b>IEEE</b>	Instituto de Engenheiros Eletricistas e Eletrônicos
<b>IGBT</b>	<i>Insulated Gate Bipolar Transistor</i>
<b>MPSO</b>	<i>Modified Particle Swarm Optimization</i>
<b>ORCS</b>	<i>One Rank Cuckoo Search</i>
<b>PSO</b>	<i>Particle Swarm Optimization</i>
<b>RAM</b>	<i>Random Access Memory</i>
<b>SA</b>	<i>Simulated annealing</i>
<b>SSO</b>	<i>Social-Spider Optimization</i>
<b>SSSC</b>	<i>Static Synchronous Series Compensator</i>

<b>STATCOM</b>	<i>Static Synchronous Compensator</i>
<b>SVC</b>	<i>Static VAR Compensator</i>
<b>UPFC</b>	<i>Unified Power Flow Controller</i>
<b>TCPS</b>	<i>Thyristor Controlled Phase Shifters</i>
<b>TCSC</b>	<i>Thyristor Controlled Series Compensator</i>
<b>TS</b>	<i>Tabu search</i>
<b>VSC</b>	<i>Voltage-Sourced Converter</i>

# Sumário

1. Introdução .....	15
1.1. Motivação .....	16
1.2. Revisão da literatura .....	18
1.3. Proposta e objetivos .....	20
1.4. Estrutura do documento .....	21
2. Dispositivos FACTS e suas características .....	22
2.1. Primeira geração de controladores FACTS .....	23
2.2. Segunda geração de controladores FACTS .....	25
2.3. STATCOM .....	26
2.4. SSSC .....	29
2.5. UPFC .....	31
2.6. Considerações finais do capítulo .....	33
3. Meta-heurísticas de otimização .....	35
3.1. Algoritmos Genéticos (GAs) .....	36
3.2. Algoritmo CROW .....	39
3.3. Algoritmo <i>Social-Spider Optimization</i> (SSO) .....	40
3.4. Algoritmo ORCS - <i>One Rank Cuckoo Search</i> .....	43
3.5. Algoritmo GWO (Grey Wolf Optimizer) .....	46
3.6. Algoritmo Dragonfly (DA) .....	51
3.7. Considerações finais do capítulo .....	54
4. Metodologia .....	56
4.1. Escolha dos dispositivos FACTS .....	57
4.2. Modelagem dos dispositivos FACTS no fluxo de potência .....	57
4.2.1. STATCOM .....	58

4.2.2.	SSSC.....	58
4.2.3.	UPFC.....	60
4.3.	Definição da função objetivo .....	61
4.4.	Consideração às condições de operação – Patamares de carga .....	62
4.5.	Escolha de Meta-heurísticas.....	63
4.5.1.	Codificação das Variáveis .....	64
4.5.2.	Outras aspectos pertinentes quanto à codificação .....	65
4.5.3.	Exemplo de codificação .....	65
4.6.	Fluxograma .....	67
5.	Simulações e Resultados .....	70
5.1.	Características do ambiente de simulação.....	70
5.2.	Casos teste.....	70
5.3.	Premissas comuns a todas as simulações.....	72
5.4.	Aferição das técnicas de otimização .....	73
5.4.1.	Sistema teste de 14 barras.....	73
5.4.1.1.	Posicionamentos obtidos.....	74
5.4.1.2.	Avaliação quanto à melhora da função objetivo .....	75
5.4.1.3.	Tempo médio de simulação.....	77
5.4.2.	Sistema teste com 118 barras .....	78
5.4.2.1.	Posicionamentos obtidos.....	78
5.4.2.2.	Melhora percentual .....	80
5.4.2.3.	Tempo de simulação.....	82
5.4.3.	Considerações quanto à aferição das técnicas de otimização .....	83
5.5.	Avaliação de desempenho .....	84
5.5.1.	Tipos de comparação avaliados.....	85
5.5.2.	Sistema IEEE de 14 barras com um patamar de carga.....	85

5.5.2.1.	Avaliação da alocação. ....	85
5.5.2.2.	Melhoria na função objetivo .....	86
5.5.2.3.	Número Médio de gerações utilizadas.....	89
5.5.2.4.	Tempo de simulação.....	90
5.5.3.	Sistema IEEE de 14 barras com três patamares de carga .....	91
5.5.3.1.	Alocação .....	92
5.5.3.2.	Melhoria da função objetivo .....	93
5.5.3.3.	Número médio de gerações .....	96
5.5.3.4.	Tempo de simulação.....	97
5.5.4.	Sistema IEEE de 118 barras.....	98
5.5.4.1.	Alocação. ....	98
5.5.4.2.	Melhoria da função objetivo.....	100
5.5.4.3.	Número médio de gerações .....	102
5.5.4.4.	Tempo de simulação.....	103
5.5.4.5.	Considerações quanto ao tempo de simulação .....	103
6.	Conclusão .....	107
6.1.	Trabalhos futuros.....	108
	Bibliografia .....	109
	Apêndice .....	114
A.1.	Sistema teste 30 barras .....	114
A.1.1.	Avaliação da alocação. ....	114
A.1.2.	Melhoria na função objetivo .....	115
A.1.3.	Número Médio de gerações utilizadas.....	118
A.1.4.	Tempo de simulação.....	120
A.2.	Sistema IEEE de 57 barras .....	121
A.2.1.	Alocação.....	121

A.2.2. Melhoria da função objetivo .....	122
A.2.3. Número médio de gerações.....	125
A.2.4. Tempo de simulação .....	126



## 1. Introdução

De maneira geral, as empresas do setor elétrico estão sujeitas a constantes desafios para proporcionar energia elétrica de forma eficiente e segura para os consumidores, tendo em vista que a insegurança ou ineficiência no fornecimento é fonte de prejuízos diversos tanto para os consumidores residenciais, como, principalmente, para os comerciais e industriais. Assim, portanto, é de suma importância a superação contínua destes desafios por parte dos agentes do setor.

Entretanto, os desafios enfrentados diferem entre os diversos países, tendo em vista diferentes características no porte e na carga do sistema. Países como o Brasil, com grande extensão territorial e distribuição populacional pouco homogênea, estão mais sujeitos aos desafios de expandir e operar uma rede elétrica interligada de maior porte que conecta os centros de geração aos centros de consumo contendo linhas de transmissão de centenas de quilômetros.

Nesse contexto, buscam-se novos mecanismos e alternativas para ampliar as melhorias técnicas e econômicas proporcionadas por estas interligações frente ao continuo crescimento no consumo de energia elétrica, com vistas a manutenção dos níveis de estabilidade e segurança do sistema, e maximizando a utilização da rede elétrica existente (PATERNI; VITET; BENA, 1999).

Dentre os diversos mecanismos e tecnologias associadas a este cenário, uma das mais efetivas e promissoras é a utilização dos denominados dispositivos FACTS. Mesmo que já existam maneiras de se contornar o problema da limitação de transmissão empregando dispositivos eletromecânicos, os mesmos se mostram, comparativamente, pouco eficientes e flexíveis, além de apresentarem resposta mais lenta e elevados custos de manutenção.

O conceito dos dispositivos FACTS (do inglês, *Flexible Alternate Current Transmission System*) é oriundo da solução deste problema, mas para tanto foi necessário que a eletrônica de potência se desenvolvesse a ponto de poder lidar com os níveis de potência e tensão exigidos pelo sistema elétrico. Assim, devido a suas características de controle, cada vez mais pesquisa tem sido realizada para a utilização

de dispositivos FACTS (SINGH; DAVID, 2000); (BANU; DEVARAJ, 2008); (PARASTAR; PIRAYESH; NIKOUKAR, 2007).

No entanto, tendo em vista o grande porte das redes elétricas e, assim, o grande número de pontos da mesma onde tais dispositivos poderão operar, a busca do ponto ideal de alocação dos dispositivos FACTS caracteriza-se como um problema de elevada complexidade, onde o tempo e esforço necessário para solucioná-lo são importantes fatores a serem considerados neste processo.

Nesse sentido, aliando-se métodos de otimização eficientes e ferramentas computacionais avançadas, torna-se possível de forma efetiva a busca pelo melhor posicionamento dos dispositivos. Devido ao crescente poder computacional, foram desenvolvidas várias meta-heurísticas de computação evolutiva e inteligência de enxame que abriram novos ramos de pesquisa para problemas de alocação de dispositivos de controle em redes de grande porte (ALHASAWI; ALABDULJABBAR, 2010); (PATERNI; VITET; BENA, 1999); (ACHARJEE, 2015).

## 1.1. Motivação

Os diversos benefícios obtidos pela utilização dos dispositivos FACTS no sentido de aumentar o poder de controlabilidade do sistema elétrico, tem despertado o interesse pela compreensão e utilização eficiente dos mesmos (PADIYAR, 2007),(SINGH; DAVID, 2000).

Assim, visando obter o máximo de aproveitamento de suas potencialidades, torna-se necessário que existam estudos para que sejam determinados os possíveis e melhores locais para a instalação de tais dispositivos no sistema elétrico de potência.

Uma das maneiras que possibilitam a pesquisa de alocação é a junção de algoritmos de otimização com algoritmos já bem estabelecidos de cálculo de fluxo de potência, de tal forma que o conjunto permita não só saber a disposição dos dispositivos, mas suas capacidades e por consequência, como o mesmo afeta as características operativas de toda a rede, permitindo portanto que sejam avaliados aspectos elétricos

como perdas de transmissão e níveis de tensão da rede, visando sempre a manutenção dos níveis mais adequados de segurança e eficiência.

Este interesse se baseia em alguns critérios que não somente o econômico gerado pelo aumento da eficiência e diminuição das perdas, mas também do fato de que, como a rede está em contínuo crescimento e a matriz elétrica mudando suas características de usinas de grande porte, para usinas de porte médio, com uma parcela crescente de fontes renováveis como a eólica, o que fez com que aumente o desafio da controlabilidade, ocasionando em algumas situações a sobrecarga de linhas e o risco de falhas sistêmicas. Um exemplo foi a ocorrência de 11 novembro de 2009 (ANEEL, 2010) onde a falha numa linha de transmissão que levava energia da usina de Itaipu à São Paulo causou um efeito cascata por todo o sistema, deixando 18 estados sem luz por 4 horas. O prejuízo só não foi maior pois a falha ocorreu depois das 22:00. No entanto, possivelmente se alguns destes avançados dispositivos de controle já estivessem em operação, tal ocorrência poderia ser evitada ou ao menos mitigada, reduzindo sua escala e impacto.

Sendo assim, existe a necessidade de se estudar o tema da alocação efetiva de controladores FACTS no sistema elétrico. Nesse sentido, existem muitos estudos relacionados com a utilização de técnicas de inteligência artificial, com destaque para a técnica de AG. Mais recentemente, novas técnicas meta-heurísticas tem sido propostas, sendo portanto fundamental que se faça uma efetiva avaliação entre as mesmas buscando evidenciar suas potencialidades quanto a utilização no tratamento de problemas de alocação.

Tendo isto em vista, é proposto neste trabalho uma comparação efetiva da adequação e desempenho de diversas meta-heurísticas de otimização para o estudo de alocação de dispositivos FACTS em sistemas elétricos de potência.

## 1.2. Revisão da literatura

Esta seção descreve estudos que tratam do problema de alocação de dispositivos FACTS e o uso de meta-heurísticas para tanto.

Em (PATERNI; VITET; BENA, 1999) é proposta a utilização de índice para mensurar o benefício dos dispositivo FACTS em série, onde as melhores localizações são fornecidas por meio de um Algoritmo Genético (GA), cujo objetivo é a de reduzir o fluxo de potência nas linhas de transmissão sobrecarregadas, visando tanto o aumento da capacidade de transmissão quanto a redução do custo de operação.

No artigo de (SINGH; DAVID, 2000) é considerado a utilização dos FACTS para melhorar o potencial de transmissão, ao passo que reduz o custo de operação, reduz a instabilidade e aumenta a controlabilidade do mesmo, onde este primeiramente determina as melhores localizações para os dispositivo e em seguida compara a redução do custo com o custo do dispositivo.

Já em (GERBEX, *et al*, 2001), os autores visaram a utilização de GA para a alocação de múltiplos tipos de FACTS em um sistema, em que a otimização tinha três parâmetros: localização, tipos e seus valores, sendo a função objetivo a capacidade de carga. Neste estudo usaram quatro FACTS: *Thyristor Controlled Series Compensator* (TCSC) , *Thyristor Controlled Phase Shifters* (TCPS), TCVR, *Static VAR Compensator* (SVC), e para realizar as simulações usaram o sistema de 118 barras do Instituto de Engenheiros Eletricistas e Eletrônicos IEEE (do inglês, *Institute of Electrical and Electronics Engineers*).

Já no artigo de (GERBEX; CHERKAOUI; GERMOND, 2003) os autores realizaram a comparação da alocação ótima utilizando os algoritmos *Simulated annealing* (SA), busca tabu (TS) e GA e os parâmetros foram localização, tipo, e tamanho e utilizaram cinco tipos de dispositivos: TCSC, TCVR, TCPS, SVC e UPFC, os quais executaram os algoritmos com base no sistema de 118 barras do IEEE para uma série de combinações de dispositivos. Os resultados das convergências destes três algoritmos foram similares e estes tiveram aumento da margem de segurança.

No artigo de (SARAVANAN *et al.*, 2005) é proposta a utilização de *Particle Swarm Optimization* (do inglês, otimização por enxame de partículas) (PSO) para a alocação de FACTS, visando a maior capacidade da rede com o menor custo de instalação de FACTS. Foram utilizados três tipos: TCSC, SVC e UPFC, bem como foram utilizados quatro parâmetros: localização, suas configurações, tipo e custo de instalação. As simulações foram realizadas com base no caso de 6 e de 30 barras do IEEE.

No caso de (PARASTAR; PIRAYESH; NIKOUKAR, 2007) é sugerida a utilização de *Modified Particle Swarm Optimization* (do inglês, PSO modificado) (MPSO) para a alocação dos dispositivos, visando diminuição das perdas e por consequência o custo de geração assim como a carga do sistema. Neste artigo os parâmetros usados foram: localização, tipo, e valor do dispositivo, sendo usado para tal o caso de 30 barras do IEEE e controladores os SVC e TCSC.

No artigo de (BANU; DEVARAJ, 2008) a proposta é a utilização de GA para eliminar as linhas sobrecarregadas e assim evitar falhas, por meio da instalação do FACTS do tipo TCSC, com a utilização do caso de 30 barras do IEEE.

Já no artigo de (MALAKAR *et al.*, 2010) é proposta a utilização de GA para determinar a alocação e capacidade ótima dos dispositivos FACTS no sistema. O sistema foi modelado utilizando de dois tipos de FACTS: TCSC e SVC, tendo o desempenho do algoritmo sido testado no caso de 30 barras do IEEE.

Em (TORTELLI; SANTOS, 2011) propôs-se a alocação de controladores FACTS levando em conta a principal funcionalidade de cada dispositivo, ou seja, o controle de tensão ou controle de fluxo, observando tanto o aspecto relativo ao planejamento da expansão quanto da operação das redes de transmissão. A lógica de otimização foi baseada no AG numa codificação binária.

No artigo de (MAROUANI *et al.*, 2011) é proposta a instalação de dispositivos FACTS para evitar sobrecargas do sistema e violações de tensão por meio da utilização dos tipos: TCSC e UPFC, e as informações obtidas por meio do GA são: localização, tipo, configurações ótimas e custo de instalação.

Já em (DEB; SIDDIQUI; IQBAL, 2015) propõem-se a utilização do algoritmo de busca gravitacional (do inglês, *Gravitational search algorithm*) (GSA) para a alocação do

dispositivo STATCOM, visto que este possui a habilidade de compensação shunt que mantem a tensão na barra onde se localiza, tendo este sido testado no caso de 14 barras do IEEE.

### 1.3. Proposta e objetivos

A alocação para instalação dos dispositivos FACTS num determinado sistema de transmissão tem despertado grande interesse. Porém a maioria dos trabalhos apresentados sobre este tema utilizam um algoritmo de otimização/meta-heurística para a obtenção do posicionamento viável.

Outra importante consideração é que muitos estudos utilizam os custos de instalação como sendo constantes para os mesmos controladores, para as mesmas configurações, indiferente da localização deste, o que simplesmente não condiz com a realidade, pois todos eles possuem valores diferentes, dependendo de sua localidade e de suas dimensões, sendo assim este parâmetro não será considerado.

Uma outra consideração, é que muitos trabalhos não consideram em um mesmo problema a variação das cargas, ou seja caracterizando tanto um problema de expansão quanto de operação, pois muitos se utilizam da carga média no sistema para a expansão enquanto que a operação se baseia em diferentes condições de carregamento, fato este que pode interferir na alocação dos FACTS.

Tendo isto em vista a atual proposta é centrada na modelagem e aplicação dos principais FACTS (STATCOM, SSSC e UPFC) todos da segunda geração, em uma ferramenta de regime permanente que servirá de base para os estudos de alocação, visando a expansão e operação do sistema.

A base de estudo será orientada na utilização de múltiplas meta-heurística, a saber: *Algoritmo genético* (AG), *Algoritmo da libélula* (*Dragonfly Algorithm*, DA), *Busca do cuco melhor ranqueado* (*One Rank Cuckoo Search*, ORCS), *Algoritmo/Otimizador dos lobos cinzentos* (*Grey Wolf Optimizer*, GWO), *Otimizador das aranhas sociáveis* (*Social-Spider Optimization*, SSO) e *Algoritmo dos Corvos* (CROW). Sendo assim a

proposta visa contribuir com a avaliação comparativa do desempenho das técnicas meta-heurísticas selecionadas, buscando determinar o comportamento das mesmas no quesito de eficiência computacional e efetividade das soluções obtidas.

#### 1.4. Estrutura do documento

Quanto a estrutura desta dissertação, está definida por seis capítulos, onde o primeiro é o de introdução ao qual é utilizado tanto para fornecer uma ideia do problema, quanto a motivação, revisão bibliográfica, assim como a proposta e objetivo.

O capítulo dois exhibe os controladores FACTS que serão utilizados no trabalho, com foco nos modelos da segunda geração, apresentando tanto suas estruturas constitutiva como seus princípios de funcionamento.

No capítulo três são expostos os algoritmos das meta-heurísticas estudados e empregados neste trabalho, apresentando o fundamento de sua origem, explicação e fluxograma dos mesmos.

O capítulo quatro, a metodologia de alocação adotada é apresentada, demonstrando tanto o porquê e como são utilizados, exibindo desta forma os dispositivos FACTS empregados e os algoritmos utilizados, assim como o princípio de funcionamento do programa criado.

No capítulo cinco são apresentadas partes das simulações realizadas, com o objetivo tanto de aferir o desenvolvimento do software criado, assim como das meta-heurísticas usadas, bem como a comparação efetiva dos algoritmos baseados em alguns critérios estabelecidos de comparação.

No capítulo seis é apresentada a conclusão e as sugestões de trabalhos futuros.

No apêndice foram incluídas simulações de caráter suplementar, com outros sistemas teste de diferentes dimensões, no mesmo sentido que as apresentadas no capítulo cinco.

## 2. Dispositivos FACTS e suas características

O sistema de transmissão de energia elétrica foi desenvolvido para suprir as demandas das cargas com confiabilidade. No entanto, os geradores, normalmente, estão situados distantes dos centros de carga, seja por questões econômicas, ambientais ou critérios de segurança. No caso específico do Brasil, a grande maioria das hidroelétricas está localizada muito distante dos principais centros de consumo, assim como as termoeletricas convencionais, mais poluidoras e as usinas nucleares, por critério de segurança, estão relativamente afastadas dos grandes centros (PADIYAR, 2007).

Além disso, o Brasil possui dimensões territoriais continentais, o que leva a um problema duplo: não só os geradores são afastados das cargas, como as próprias cargas são afastadas entre si, obrigando o sistema de transmissão a ser muito mais complexo do que outros com características de consumo similares. Como exemplo, a Coreia do Sul, que com uma área em torno de 85 vezes menor que a do Brasil apresentou um consumo de energia elétrica durante o ano de 2013 similar ao brasileiro, em torno de 500TWh (MINAS E ENERGIA, 2015).

Adicionalmente, existe a necessidade da existência de um número razoável de interconexões na rede de transmissão, por razões econômicas e de segurança, a fim de distribuir melhor a energia, diminuindo a sobrecarga de linhas, perdas elétricas, flutuações de tensão, assim como evitar panes na rede, que poderiam derrubar partes desta, deixando áreas sem ou com insuficiência de atendimento.

A rede de transmissão de energia elétrica na sua composição convencional, não possui um controle efetivo do fluxo de potência, de forma que o mesmo é feito usualmente de forma indireta através da atuação sobre geradores e/ou cargas do sistema.

Sendo assim é relevante considerar a introdução de novos componentes com capacidade de controle atuando no sistema de transmissão. Ou seja, para que se possa passar de um controle passivo da rede para um controle mais ativo, é necessário que se instale dispositivos que permitam esta operação, que é realizada pela mudança das características locais da rede. Tais dispositivos são os FACTS.



Tais dispositivos, agrupados pelo acrônimo FACTS são equipamentos que, por meio de eletrônica de potência, permitem atuar sobre o sistema elétrico visando torna-lo confiável, eficiente e flexível. Além disso, permitem também evitar alguns problemas na operação do sistema, tais como oscilações causadas pelas cargas, excesso de potência reativa, que pode levar a sobrecargas das linhas de transmissão, aumentando as perdas ativas.

Assim, os principais benefícios proporcionados pelos Controladores FACTS são:

- Regulação de tensão;
- Redução de perdas na transmissão;
- Aumento da capacidade de transmissão;
- Aumento dos limites de estabilidade transitória;
- Amortecimento de oscilações.

A seguir serão apresentados e descritos os principais controladores FACTS, divididos nas suas duas gerações tecnológicas, em função da evolução das chaves eletrônicas de potência: a primeira, caracterizada pela utilização de tiristores e uma segunda geração, baseada no emprego de chaves eletrônicas com capacidade de controle do disparo e bloqueio, como o GTO (*Gate Turn-off Thyristor*) e o IGBT (*Insulated Gate Bipolar Transistor*) (PADIYAR, 2007).

## 2.1. Primeira geração de controladores FACTS

Assim como em quase todo processo de desenvolvimento, os Controladores FACTS também devem sua origem à evolução das ideias e da tecnologia. Neste caso, a ideia original baseou-se em ações de controle convencionais, tais como a utilização de bancos de capacitores e transformadores de tap variável. No entanto, estes são fixos, ou podem ser ajustados de maneira discreta pela atuação de operadores.

A outra área associada a esse processo de desenvolvimento tecnológico foi a eletrônica, e, de forma mais específica a eletrônica de potência, com o aprimoramento de materiais semicondutores que propiciaram a contenção de chaves eletrônicas, cujo princípio básico já era conhecido, como os tiristores, porém com a capacidade de


suportar altas correntes e altas tensões, de forma a poderem ser aplicados a conversores de alta potência. A junção destes dois conceitos deu origem aos primeiros Controladores FACTS baseados em conversores tiristorizados.

Em função de seu baixo custo, alta eficiência e capacidade de suportar elevadas tensões e correntes, os tiristores de potência são largamente empregados em projetos de conversores de alta potência. Assim, a primeira geração de conversores FACTS tem seu funcionamento atrelado às características dos próprios tiristores, que possuem apenas o modo ativação, ou seja, depois de postos em condução pela ação da ordem de disparo, bloqueiam apenas com a anulação da corrente. Esta característica implica na operação destes conversores na frequência da rede, visto que por ser tiristorizado, depende do término do ciclo da rede para que o tiristor seja desativado.

Os controladores FACTS desenvolvidos com esse conceito têm como característica comum o fato de se comportarem, em regime permanente, como uma impedância equivalente aplicada a rede elétrica onde estão conectados. O valor da impedância equivalente (capacitiva ou indutiva) é controlada eletronicamente pelo ângulo de disparo dos tiristores (PADIYAR, 2007).

Das diversas configurações aplicáveis aos controladores FACTS da primeira geração, a mais típica é a que combina um capacitor fixo em paralelo com um reator controlado por tiristor (FC-TCR). A figura 2.1 mostra, de forma esquemática, essa estrutura básica.

Figura. 2.1. Primeira geração de controladores FACTS - Estrutura básica



Fonte: (TORTELLI, 2010)

Os principais controladores FACTS desta geração são:

- *Thyristor Controlled Phase Shifters* (TCPS): Controlador inserido em série com a rede elétrica, com a potencialidade de controlar o fluxo de potência ativa por meio da atuação sobre a abertura angular da tensão.
- *Thyristor Controlled Series Compensator* (TCSC): Controlador série, com a potencialidade de controlar o fluxo de potência ativo por meio da variação na impedância da linha de transmissão.
- *Static VAR Compensator* (SVC): Controlador shunt, com a potencialidade de atuar no controle da magnitude de tensão, pela injeção ou absorção de reativos do sistema.


## 2.2. Segunda geração de controladores FACTS

A segunda geração de controladores FACTS está baseada no desenvolvimento de conversores do tipo fonte de tensão (ou do inglês VSC, *Voltage-Sourced Converter*), possíveis a partir do desenvolvimento e aplicação de chaves eletrônicas mais avançadas, como os tiristores com capacidade de bloqueio comandado (GTO, do inglês, *Gate Turn-Off*) e os IGBTs (do inglês, *Insulated Gate Bipolar Transistor*) de potência (PADIYAR, 2007).

Estes semicondutores de potência com capacidade de bloqueio (autocomutados) podem operar com frequências mais elevadas, bem acima da frequência da rede elétrica. Embora isso possa aumentar as perdas por chaveamento, por outro lado faz com que as operações de controle possam ser eficientes. Além disso, pelo fato de proporcionarem o desenvolvimento de conversores com conceitos e características de desempenho mais avançados, podem produzir uma redução significativa de tamanho do sistema como um todo, sendo responsáveis por ampliar as potencialidades de controle da rede elétrica.

A figura 2.2 mostra a estrutura típica de um conversor tipo fonte de tensão (VSC) e sua representação equivalente, indicando sua característica fundamental, ou seja, a de gerar uma tensão síncrona com magnitude e ângulo de fase controláveis.

Figura 2.2: Estrutura típica e representação equivalente do Conversor tipo VSC



Fonte: (TORTELLI, 2010)

onde  $Z_U$  é a impedância do conversor e  $V_U$  é a tensão fornecida pelo conversor.

Os principais Controladores FACTS da segunda geração são: o STATCOM, o SSSC e o UPFC.

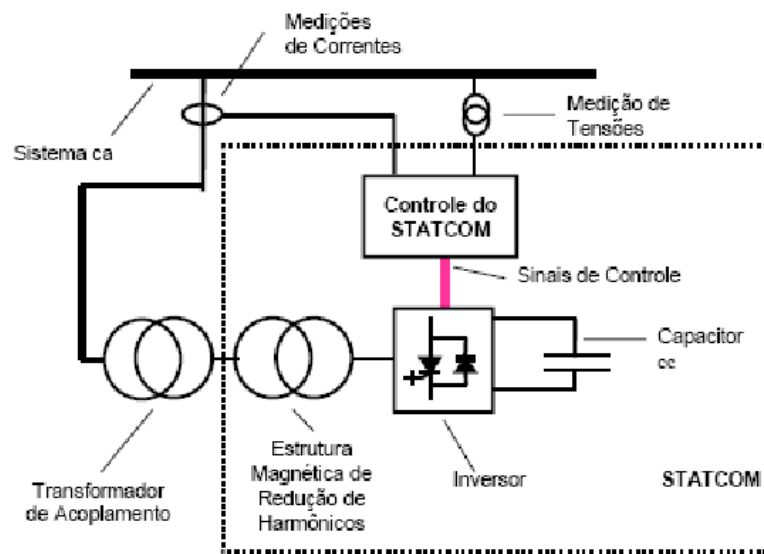
### 2.3. STATCOM

Em regime permanente, o STATCOM funciona como uma fonte de tensão eletronicamente controlada, conectada em paralelo com a rede de potência por meio de um transformador de acoplamento, de modo semelhante ao de um compensador síncrono, porém sem a inércia mecânica, podendo fornecer ou absorver potência reativa da rede elétrica, sendo, portanto utilizado para regulação de tensão.

Devido ao fato de seu princípio de funcionamento se basear na atuação de conversores multipulsos e multiníveis, possui uma resposta mais rápida que o controlador SVC, ou seja controla a magnitude de tensão na barra por meio da absorção ou injeção de reativo, contribuindo para melhorar a característica de transmissão e estabilidade do sistema elétrico, sendo portanto caracterizado como controle de apenas dois quadrantes (ACHA; KAZEMTABRIZI, 2013) e (YANG *et al.*, 2000).

Na sua forma mais simples, o STATCOM é constituído de um transformador de acoplamento, um VSC e um dispositivo acumulador de energia, usualmente um capacitor DC (Corrente Contínua). A estrutura básica de um STATCOM é apresentada na figura 2.3.

Figura 2.3: Estrutura básica do STATCOM




Fonte: (TORTELLI, 2010)

#### Princípio de Funcionamento:

O princípio de funcionamento do Statcom pode ser mais facilmente compreendido através da sua representação equivalente apresentada na figura 2.4, onde  $V_K$  é a tensão na barra K,  $B_{stt}$  é a impedância do STATCOM e  $V_{stt}$  é a tensão fornecida pelo STATCOM.

Figura 2.4: Representação equivalente do Conversor STATCOM



Fonte: (TORTELLI, 2010)

Assumindo uma operação em regime permanente sem perdas, onde, neste caso, o fluxo ativo pelo STATCOM é nulo, ou seja  $P_{stt}=0$ , implica que a defasagem angular entre a barra e o conversor é nula, ou seja  $\theta_{stt} = \theta_k$ .

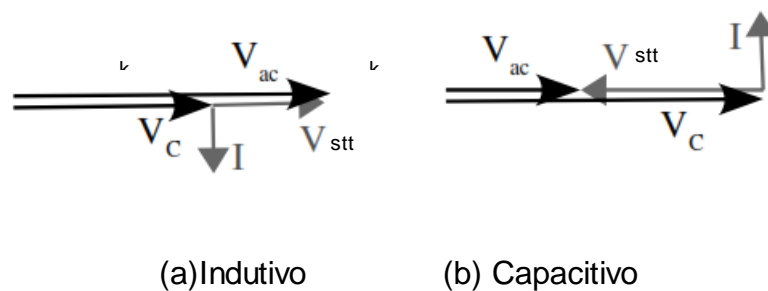
Sendo assim a função que representa a potência reativa trocada entre o conversor e o sistema elétrico pode ser definida pela seguinte equação:

$$Q_{stt} = -V_{stt}^2 \cdot B_{stt} + V_{stt} \cdot V_k \cdot B_{stt} \quad (2.1)$$

Onde,  $Q_{stt}$  é a potência reativa injetada ou absorvida,  $V_{stt}$  é a tensão proporcionada pelo equipamento,  $B_{stt}$  é a impedância equivalente do equipamento e  $V_k$  é a tensão especificada da barra controlada pelo STATCOM.

Assim, considerando que a magnitude da tensão do sistema elétrico é mantida constante, se o STATCOM operar com tensões abaixo da tensão da rede, o compensador passa a operar como um banco de indutores variáveis, gerando correntes atrasadas de  $90^\circ$  em relação à tensão do sistema elétrico. Por outro lado, se a magnitude da tensão for variada com amplitudes maior que a da rede, o STATCOM passa a injetar potência reativa, operando como um banco de capacitores variável. A figura 2.5 apresenta essas duas formas de operação através de diagramas fasoriais.

Figura 2.5: Diagramas Fasoriais dos modos de operação do STATCOM



Fonte: (TORTELLI, 2010)


## 2.4. SSSC

Da mesma forma que o STATCOM, este dispositivo funciona como uma fonte de tensão controlada, porém conectado em série com a rede.

Assim, enquanto o anterior controla a tensão em um barramento da rede, este atua na diferença de tensão da linha de transmissão, permitindo o controle do fluxo de potência ativo e reativo, a partir do controle da magnitude e da posição angular da tensão injetada com relação a corrente na linha.

A estrutura básica de um compensador SSSC é constituída por um transformador de acoplamento, um VSC e um dispositivo acumulador de energia, usualmente um capacitor de corrente contínua (DC), como apresentado na figura 2.6.

Figura 2.6: Esquema do SSSC




Fonte: (ZHANG, 2003)

### Princípio de Funcionamento:

O compensador SSSC gera tensões em quadratura, em avanço ou atraso de fase, em relação à corrente da linha, e pode ser considerado, funcionalmente, como uma fonte de tensão ideal, com amplitude e ângulo de fase controlável, conectada em série com a rede elétrica, conforme mostrado na figura 2.7.

Figura 2.7: circuito equivalente ao esquema do SSSC



Fonte: (KAMEL; ABDEL-AKHER; EL-NEMR, 2010)

Com base no circuito equivalente pode-se chegar às equações de fluxo de potência ativa e reativa associadas ao ramo que contém o Controlador SSSC, apresentadas a seguir:

$$P_k = \frac{|V_k||V_m|}{X_{SSSC}} \sin(\theta_k - \theta_m) + \frac{|V_k||V_{SSSC}|}{X_{SSSC}} \sin(\theta_k - \theta_{SSSC}) \quad (2.2)$$

$$Q_k = \frac{|V_k|^2}{X_{SSSC}} - \frac{|V_k||V_m|}{X_{SSSC}} \cos(\theta_k - \theta_m) - \frac{|V_k||V_{SSSC}|}{X_{SSSC}} \cos(\theta_k - \theta_{SSSC}) \quad (2.3)$$

Onde,  $\theta_k$ ,  $\theta_m$  e  $\theta_{SSSC}$  são respectivamente os ângulos de  $K$ ,  $M$  e do SSSC,  $V_k$ ,  $V_m$ ,  $V_{SSSC}$  são respectivamente as tensões de  $K$ ,  $M$  e do SSSC, e  $X_{SSSC}$  é a impedância do SSSC.

Assim, o SSSC pode interferir nas potências ativa e reativa do sistema CA, a partir do controle da magnitude e da posição angular da tensão injetada com relação a corrente na linha, constituindo-se numa importante e avançada alternativa à compensação série convencional, baseada em reatâncias variáveis.




## 2.5. UPFC

O UPFC pode ser entendido como uma combinação do STATCOM com o SSSC num único dispositivo, o que confere ao mesmo uma capacidade ampliada de controle.

A partição STATCOM é conectada por meio de um transformador de acoplamento na disposição de shunt, controlando assim a tensão no barramento e a potência shunt reativa. Por outro lado a partição SSSC é conectada por um transformador de acoplamento inserido na linha de transmissão, na qual é controlada a diferença de tensão nesta seção, permitindo o controle tanto do fluxo reativo quanto do ativo (ACHARJEE, 2015).

A representação esquemática do UPFC, é constituído de dois transformadores de acoplamento, dois VSC e um dispositivo acumulador de energia, usualmente um capacitor DC, conforme apresentado na figura 2.8.

Figura 2.8: Diagrama do UPFC



Fonte: (TIWARI; NIAZI; GUPTA, 2012)

onde,  $V_{se}$  é a tensão do controlador na seção série,  $V_{sh}$  é a tensão do controlador na seção shunt e os  $V_i$  e  $V_j$  são as tensão nas barras  $i$  e  $j$ .

### Princípio de Funcionamento:

Como pode ser observado da representação esquemática mostrada na figura 2.8, o UPFC consiste da associação de dois conversores VSC que compartilham um mesmo capacitor DC. Um dos conversores é acoplado à rede elétrica através de um transformador em série e o outro através de um transformador em *shunt*.

Devido ao fato de que este compartilha a mesma fonte DC para os seus módulos STATCOM e SSSC, a expressão a seguir deve ser observada para garantir que o balanceamento de ativo que circula por entre os módulos seja idealmente nula:


$$\text{Re}(-V_{vR}I_{vR}^* + V_{cR}I_m^*) = 0 \quad (2.4)$$

$$P_{stt} + P_{sssc} = 0 \quad (2.5)$$

Onde  $P_{stt}$  e  $P_{sssc}$  são as potências ativas controladas pelas seções STATCOM e SSSC do UPFC,  $V_{vR} I_{vR}^*$  são tensão e corrente na conexão série do controlador e  $V_{cR} I_m^*$  e são tensão e corrente na conexão shunt do controlador.

No controle dos fluxos de potência, o UPFC pode assumir diversas funções dependendo da magnitude e fase da tensão aplicados, como ilustrado na figura 2.9

Figura 2.9: Modos de Operação do UPFC - Diagramas fasoriais



Fonte: (TORTELLI, 2010)

(a) Regulação da tensão de barra: O UPFC injeta uma tensão de  $V_cR$  em fase com  $V_o$ , resultando numa ação semelhante a de um transformador LTC.

(b) Compensação série: a tensão  $V_cR$  é aplicada em quadratura com a corrente  $I_r$ , proporcionando um efeito similar ao conseguido com um capacitor.

(c) Controle multifunção: as funções descritas em (a) e (b) são executadas simultaneamente.

Dessa forma o UPFC constitui-se no mais complexo e versátil dos controladores FACTS, sendo um avançado dispositivo de controle do sistema elétrico de potência, com capacidade de controlar simultaneamente magnitude de tensão e fluxos de potência ativa e reativa.

## 2.6. Considerações finais do capítulo

Neste capítulo, tratou-se das características e modelagem elétrica das duas gerações de Controladores FACTS.

A primeira geração desenvolvida, teve como base a utilização de conversores tiristorizados, proporcionando dispositivos de controle em série e shunt. Já a segunda geração, de desenvolvimento mais recente, é baseada no emprego de chaves eletrônicas auto comutadas que proporcionam conversores com potencial de controle mais avançado e eficiente da rede elétrica.

Devido aos problemas associados ao SEP, já existem dispositivos FACTS em operação em diversos países. Dentre estes, os que possuem os de maior capacidade são os Estados Unidos, Japão, China e Índia. Dentre estes, podem ser destacados: Controlador UPFC nos Estados Unidos, que se situa em uma área com 2000 MW de carga, que além de aumentar a capacidade de transmissão das linhas, diminuiu a perda em 24 MW; Controladores TCSC na interligação Norte-Sul do Sistema Brasileiro, que permitiram a conexão de uma linha AC de 1000 Km, amortecendo as oscilações entre os dois sistemas que antes operavam isolados; Controladores SVC na Tailândia, que

após sua implementação melhoraram a capacidade de linhas de transmissão sobrecarregadas que conectavam os principais geradores às cargas distantes 700Km. (ACHARYA; YOME; MITHULANANTHAN, 2004)

Portanto devido a estas características e eficiências obtidas, os principais conversores FACTS da segunda geração foram considerados nos estudos de alocação tratados nesta dissertação.

### 3. Meta-heurísticas de otimização

Da mesma forma que as sociedades se desenvolvem, o desejo de otimizar novos processo também vai se desenvolvendo, chegando a métodos eficientes de otimização disponíveis atualmente, capazes de projetar definir além de melhores caminho, melhorar sistemas e processos, tanto do ponto de vista técnico como econômico.

Assim, devido a este crescimento de complexidade, novas técnicas de otimização foram desenvolvidas, baseando-se na replicação de certos aspectos da natureza e passaram a ser tratados como estudos de Inteligência Artificial (I.A.), pois os algoritmos possuíam comportamento inteligente, comparáveis em certos aspectos aos originais.

Este conjunto de algoritmos “estuda os casos em que as restrições ou os parâmetros dependem de variáveis aleatórias” (KLEIN *et al.*, 2016).

Uma das definições para meta-heurística é dada por (KLEIN *et al.*, 2016): “são métodos de solução que coordenam procedimentos de busca locais com estratégias de mais alto nível, de modo a criar um processo capaz de escapar de mínimos locais e realizar uma busca robusta no espaço de soluções de um problema”. Posteriormente, a definição passou a abranger quaisquer procedimentos que “empregassem estratégias para escapar de mínimos locais em espaços de busca de soluções complexas. Em especial, foram incorporados procedimentos que utilizam o conceito de vizinhança para estabelecer meios de fugir dos mínimos locais. Uma meta-heurística, portanto, visa produzir um resultado satisfatório para um problema, porém sem qualquer garantia de otimalidade” (KLEIN *et al.*, 2016).

Dessa forma, meta-heurísticas são aplicadas para encontrar respostas a problemas sobre os quais há poucas informações: não se sabe como é a aparência de uma solução ótima, há pouca heurística disponível e força-bruta é desconsiderada devido ao espaço de solução ser muito grande. Porém, dada uma solução candidata ao problema, esta pode ser testada e sua otimalidade averiguada (LUZIA; RODRIGUES, 2009).

Além disso, (NETO *et al.*, 2009) resumem o conceito de meta-heurísticas como: “mecanismos de alto nível para explorar espaços de busca, cada uma usando um determinado tipo de estratégia”.

Neste trabalho serão abordadas seis técnicas Meta-heurísticas de otimização descritas em maiores detalhes a seguir.

### 3.1. Algoritmos Genéticos (GAs)

O GA foi um dos primeiros algoritmos a se diferenciar dos métodos tradicionais de busca e otimização. O GA se diferencia em quatro principais aspectos: trabalham com uma codificação do conjunto de parâmetros e não os próprios parâmetros, se utilizam de uma população e não somente um único ponto, se baseia no custo ou recompensa sem conhecimento auxiliar e se utilizam de regras de transição probabilísticas e não determinísticas.

Tal algoritmo foi baseado na imitação da natureza, no caso uma população de indivíduos sofrendo da seleção natural, inicialmente partindo de uma população aleatória, em que os genes dos indivíduos são a possível solução para o problema, durante o processo evolutivo cada integrante desta, é atribuído um valor, o resultado de sua solução, que se reflete na adaptação deste ao ambiente, sendo assim, assim como na natureza os mais adaptados são os que passam a informação adiante no decorrer das gerações (CARVALHO, 2017).

Os componentes deste algoritmo podem ser agrupados em cinco principais (DETORAKIS; TAMBOURATZIS, 2007):

#### i) Avaliação:

Após a formação da população inicial do problema, esta é executada podendo ser tanto em série quanto em paralelo, retornando assim um valor específico atrelado à função objetivo (fitness). Este valor de fitness corresponde a quão boa é a solução do problema para um possível indivíduo. Sendo assim é possível dizer que a função de

adequação, fitness, representa o ambiente de estudo onde a população irá se desenvolver e caminhar para a obtenção do resultado.

ii) Seleção:

De forma similar ao que acontece na natureza, cada par produz dois filhos. Assim como na natureza, os mais aptos tem mais chances de passar suas boas qualificações para a próxima geração. A probabilidade  $Pr_k$  de um indivíduo ser selecionado como pai é relacionado a nota/resultado (grade) de sua avaliação.

$$Pr_k = \frac{NOTA_k}{\sum_{j=1}^N NOTA_k} \quad (3.1)$$

onde,  $NOTA_k$  é o resultado da função objetivo para o indivíduo  $k$  da população, e  $N$  é o número total de indivíduos da população.

iii) Cruzamento (*Crossover*):

É a recombinação dos genomas dos pais para criar os filhos, ou seja, ocorre a seleção dos genes por meio de um vetor binário aleatório. Uma das formas de cruzamento existente é aquela em que os genes são provenientes de dois indivíduos da geração anterior nas quais uma parte é oriunda de um pai e outra de outro pai, originando assim uma nova cadeia de genes.

iv) Elitismo:

Outro método utilizado no GA para a transferência de genes de uma geração à outra é por meio de elitismo, onde uma parcela da população é diretamente transferida para a próxima geração, onde os melhores da população são transferidos, preservando os melhores resultados na população.

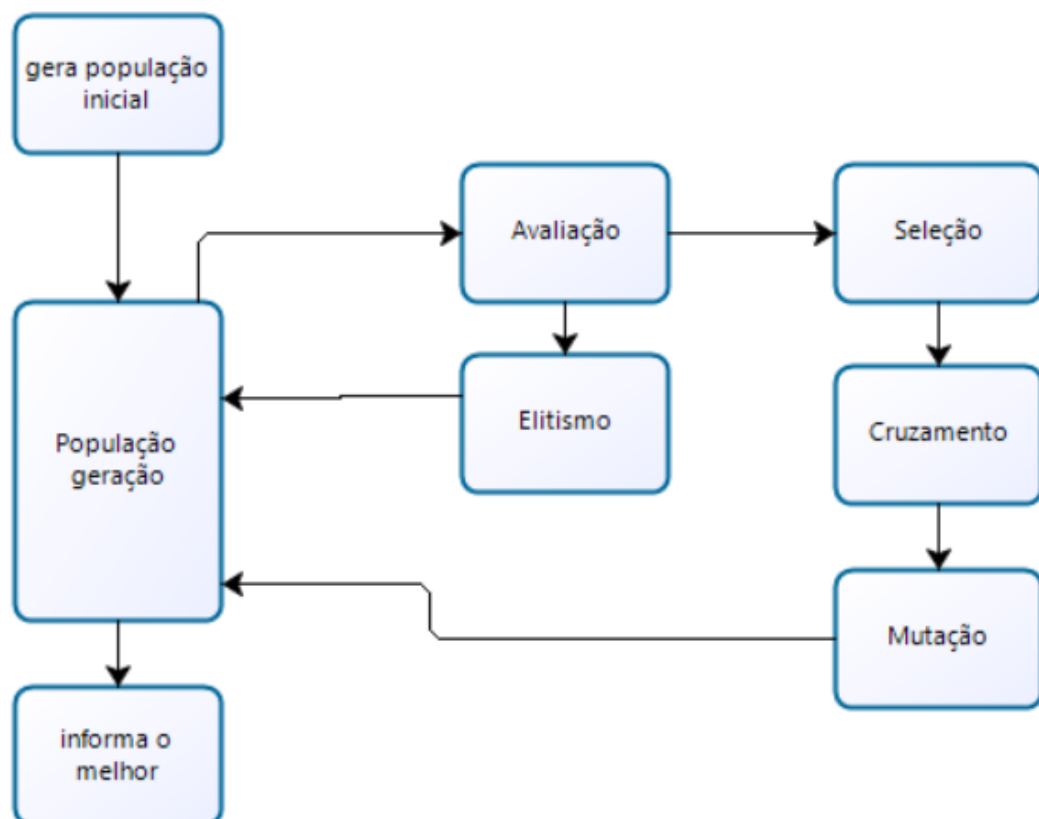
Este método é utilizado, devido ao fato que o crossover e a mutação, destroem as informações da geração pai, sendo assim uma importante ferramenta que auxilia na convergência do algoritmo.

v) Mutação:

Antes de terminar de criar a nova geração, os filhos sofrem mutação com uma certa probabilidade. Esta mutação é necessária para introduzir na população elementos randômicos, gerando assim novos valores, das quais a população original não poderia dispor. Assim, permite-se que a população seguinte tenha novas propriedades, facilitando tanto a convergência a um possível resultado de forma mais rápida, quanto diminui a probabilidade do algoritmo de convergir para um resultado ótimo local, possibilitando assim o encontro de outros ótimos.

Assim, os passos mais importantes do GA, podem ser relacionados como apresentado na figura 3.1.

Figura 3.1: Diagrama dos passos mais importantes do GA



Fonte: Adaptado de (DETORAKIS; TAMBOURATZIS, 2007)



### 3.2. Algoritmo CROW

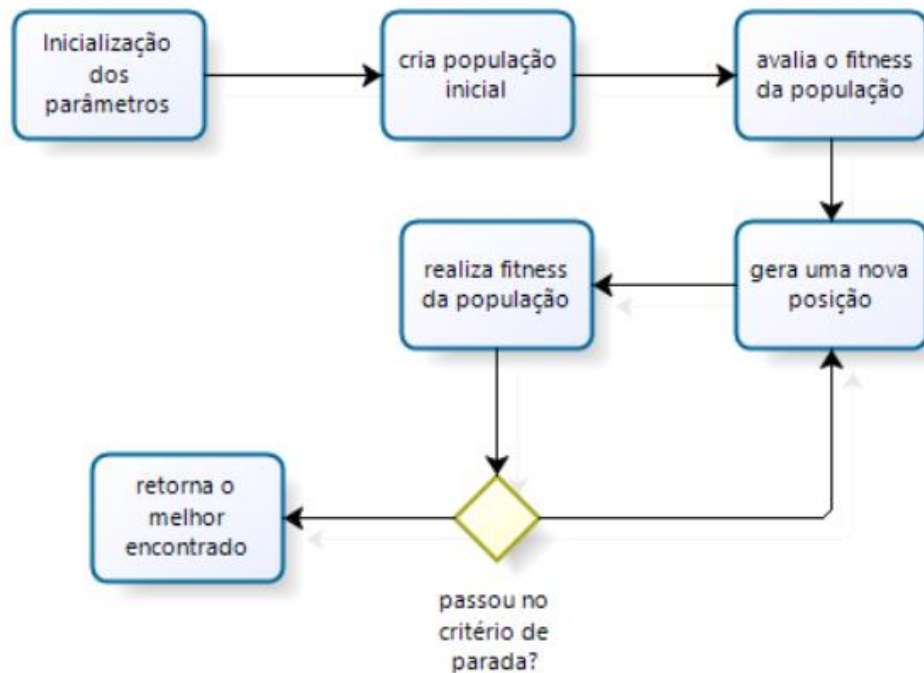
Desenvolvido nos últimos anos, o algoritmo CROW é uma nova abordagem que se utiliza de população como um dos seus parâmetros (COELHO *et al.*, 2016), possui com base natural um dos mais engenhosos pássaros, que é considerado um dos mais inteligentes animais existentes no mundo, o corvo. Quando em grupo, mostram uma grande capacidade de realizar testes de inteligência, assim como memorização, uso de ferramentas, comunicação e incrível estratégia para encontrar e esconder comida durante o passar das estações. Este último é que inspira a estratégia do algoritmo CROW (COELHO *et al.*, 2016).

No algoritmo CROW, o funcionamento é similar ao AG em termos das variáveis/genes. Enquanto no AG são os genes que definem os dados (valor atribuído as variáveis), no CROW assim como em outros algoritmos do tipo enxame de partícula, os dados são referenciados ao posicionamento espacial de  $N$ -dimensões, sendo  $N$  o número de variáveis estudadas.

A técnica foi desenvolvida após a observação de que grupos de pássaros percorrem o espaço de forma aparentemente aleatória, em busca de alimento, e seguindo o pássaro mais próximo do objetivo. Essa busca coordenada pelo grupo é chamada de inteligência de enxame. Ou seja cada partícula/indivíduo representa uma solução no espaço de busca (RAJPUT *et al.*, 2016).

O algoritmo se baseia nos seguintes passos:

Figura 3.2: Fluxograma do algoritmo CROW



Fonte: Adaptado de (RAJPUT *et al.*, 2016)

### 3.3. Algoritmo *Social-Spider Optimization* (SSO)

Nos últimos anos, tem-se tido um número crescente de grupos estudando diversos animais em seus ambientes em busca dos comportamentos inteligentes, o que atraiu muitos que buscavam aplicá-los em algoritmos para diferentes problemas de otimização, sendo um destes o *Social-Spider Optimization* (SSO).

O SSO se baseia no comportamento de cooperação entre os indivíduos. O Algoritmo leva em conta os dois gêneros de aranhas de busca: masculino e feminino. Cada um tem seu comportamento distinto na colônia de aranhas. A teia das aranhas se baseia no espaço de busca, enquanto que seu posicionamento no espaço se refere aos valores de suas variáveis, ou seja uma possível solução, onde cada indivíduo neste caso é uma aranha (ZAWBAA *et al.*, 2015).

Uma das características deste é que diferentemente dos humanos em que a tendência é ser 50-50 % (relação entre masculino e feminino), é de no máximo 35% para aranhas macho ( $Nm$ ) e de 65-90% para as aranhas fêmea ( $Nf$ ). Assim a faixa de variação aleatória considerada para o parâmetro  $Nf$  é de 0.65 até 0.90 (PEREIRA *et al.*, 2014).

Logo a população de aranhas masculinas são dadas por:

$$Nm = N - Nf \quad (3.2)$$

Cada aranha recebe um peso conforme o valor do fitness encontrado, que é dado por:

$$Peso_i = \frac{fitness_i - Pior}{Melhor - Pior} \quad (3.3)$$

Onde o fitness é o valor encontrado para a posição da aranha, o pior e o melhor são os resultados respectivos da geração (KLEIN *et al.*, 2016).

Para simular as vibrações existentes na natureza, são usadas tanto o peso quanto a distância entre as mesmas. Isso é importante pois é usada para o acasalamento para a criação da próxima geração. A formula da vibração pode ser dada da seguinte forma:

$$V_{i,j} = (Peso_i) \cdot e^{-d_{i,j}^2} \quad (3.4)$$

Onde:

$d_{i,j}$  = distância euclidiana entre as aranhas  $i$  e  $j$ ;

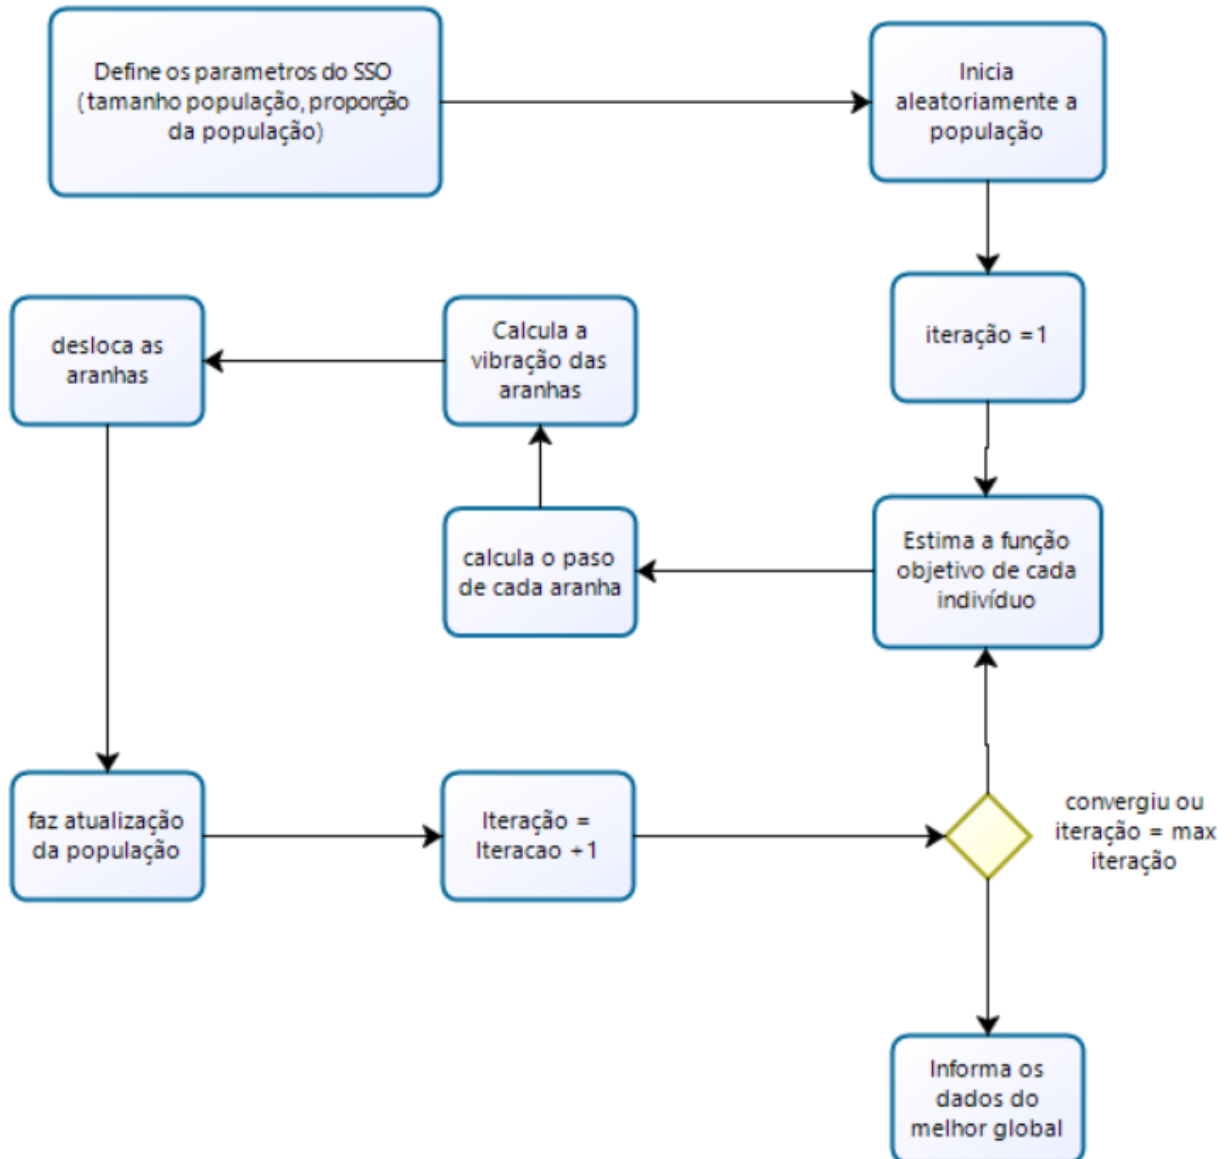
$Peso_i$  = fitness da aranha  $i$ .

O comportamento das aranhas dependem do sexo e do tipo das mesmas: se as aranhas forem macho, podem ser dominantes e não dominantes, onde os dominantes são os que possuem os melhores fitness. Levando isto em conta, as aranhas dominantes são mais atraentes para as fêmeas mais próximas e os não dominantes ficam com o que resta (PEREIRA *et al.*, 2014).

Já o acasalamento entre elas acontece somente entre aranhas macho dominantes e as aranhas fêmea, onde a nova aranha é obtida e comparada com a população e se verifica se o obtido é pior ou melhor que a de pior fitness da população existente. Caso seja melhor, a pior é substituída pela nova.

Sendo assim o fluxograma abaixo mostra melhor as etapas deste algoritmo.

Figura 3.3: Fluxograma algoritmo SSO



Fonte: Adaptado de (EL-FERGANY; EL-HAMEED, 2017)

### 3.4. Algoritmo ORCS - *One Rank Cuckoo Search*

O algoritmo ORCS se baseia em uma espécie de ave, o cuco, cujas ramificações existem no mundo inteiro. Trata-se de uma espécie parasitária, quer dizer, em algum momento de sua vida, depende de outra espécie para sobreviver, sem ser uma troca mútua, mais especificamente na criação de sua prole.

A ave deposita seu ovo no ninho de outra ave. Se a dona do mesmo não percebe, choca a da parasita, quando esta nasce, se desfaz dos outros ovos, e imita o chamado caso este não venha a ser o primeiro a nascer, aumentando a chance de obter alimentos da mãe adotiva.

As falhas acontecem quando a dona do ninho percebe que o novo ovo não lhe pertence, este pode tanto retirar o ovo, ou simplesmente iniciar outro ninho, no entanto este passo é minimizado pois as espécies se adaptaram a deixar ovos similares aos originais. Outra falha pode ocorrer no caso do nascimento, pois o preferível para a espécie é ser o único no ninho, pois o ovo novo pode ser posto depois de muito tempo, porém os ovos desta espécie costumam chocar muito rápido.

Ou seja a mãe tem maior chance de deixar prole, devido a estas adaptações, devido a isto, esta espécie foi estudada e assim criado um algoritmo que mimetize parte de seu comportamento.

No caso do algoritmo, cada ovo no ninho representa uma solução, e como existe apenas um ovo por ninho, cada ovo é uma solução, o algoritmo em si segue apenas duas regras:

- Cada cuco deposita apenas um ovo por vez, e escolhe aleatoriamente.
- Cada ninho com alta qualidade (solução), será a próxima geração.

O número de ninhos disponíveis é fixo, e a probabilidade de descoberta do ovo pelo dono do ninho é definida. A taxa opera sobre os piores ninhos, caso descoberto a solução é retirada.

Já o posicionamento do ninho escolhido é randomicamente selecionado, por exemplo em uma área de busca bidimensional o posicionamento da ave e por consequência do ovo é dado por:

$$x_i^{t+1} = x_i^t + L(k) \quad (3.5)$$

$$L(k) = 0.01 \frac{r_1 \sigma}{|r_2|^{\frac{1}{\beta}}}$$

$$\sigma = \left( \frac{\Gamma(1 + \beta) \sin\left(\frac{\pi\beta}{2}\right)}{2^{\left(\frac{\beta-1}{2}\right)} \beta \Gamma\left(\frac{1+\beta}{2}\right)} \right)^{\frac{1}{\beta}}$$

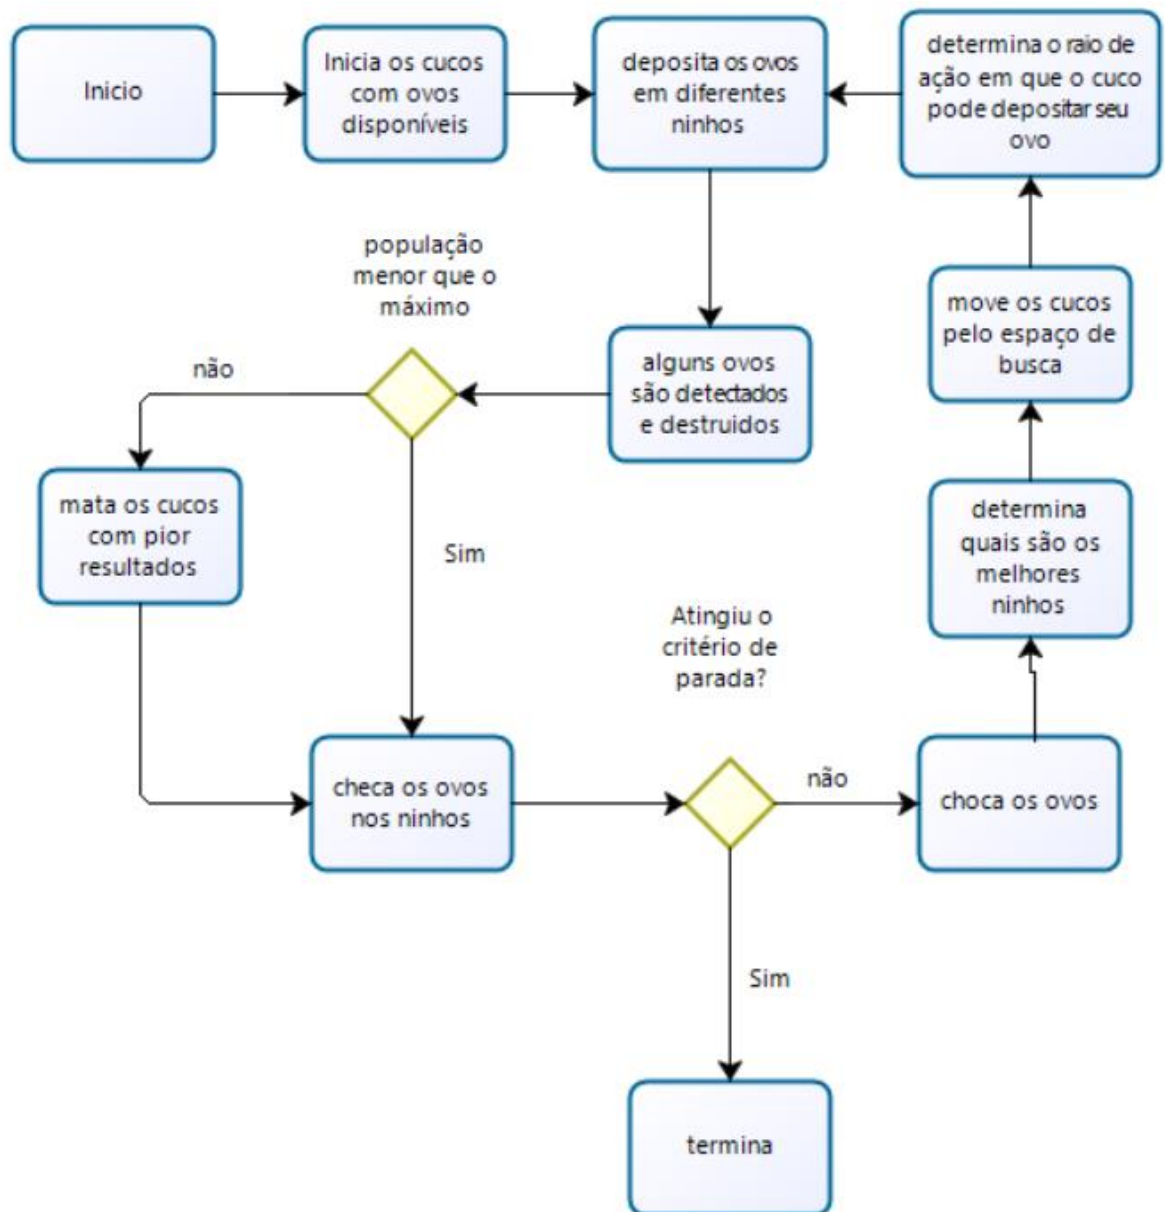
$$\Gamma(x) = (x - 1)! \quad (3.6)$$

Onde  $r_1$  e  $r_2$  são números randômicos e  $\beta$  é um número constante,  $k$  é a distância ao qual pode ser percorrida, normalmente fornecida por cálculo com randômicos (RAJPUT *et al.*, 2016).

Ou seja o “vôo de Lèvy” ou  $L$  na fórmula é definido por ser aleatório, para assim imitar o voo deste animal na natureza.

O algoritmo é representado em forma de fluxograma da seguinte forma:

Figura 3.4: Fluxograma do algoritmo ORCS



Fonte: Adaptado de (RAJPUT *et al.*, 2016)

### 3.5. Algoritmo GWO (Grey Wolf Optimizer)

Desenvolvido por meio dos contínuos avanços em pesquisa dos ambientes naturais em busca de comportamentos inteligentes, o algoritmo GWO é inspirado no comportamento dos lobos cinzentos.

Estes costumam viver em grupos de cinco a 12 indivíduos e estão no topo da cadeia alimentar. O grupo se ramifica em quatro tipos que dominam sua hierarquia: Alpha ( $\alpha$ ), Beta ( $\beta$ ), Delta ( $\delta$ ) e Ômega ( $\omega$ ). Os alpha são os mais dominantes da alcateia, tomam a maior parte das decisões como caça, local para dormir, hora para acordar, entre outros. Não necessariamente este são os mais fortes, mas sim os melhores em gerenciar o grupo.

A posição dos lobos beta é intermediária aos alpha e delta. Seu trabalho é disciplinar o grupo recebendo comandos do alpha. Costumeiramente os betas são os melhores para serem os próximos alpha, quando estes morrem ou envelhecem demais para realizarem os trabalhos de forma eficiente.

Os mais fracos são os Deltas e Ômegas, onde estes últimos se submetem a todos os outros na hierarquia, sendo por exemplo os últimos a comer. Ambos podem desempenhar papéis como babás dos mais jovens, assim como sentinelas, exploradores, caçadores e cuidadores (responsáveis pelos limites dos territórios) e alertam qualquer perigo. Além disso, por serem os mais velhos ajudam o alpha na caçada por possuírem mais experiência (BIYANTO *et al.*, 2016); (DAS; DAS; DAS, 2015); (SETH; CHANDRA, 2016).

A figura 3.5 demonstra características do comportamento dos lobos quando em grupos, tais como: comportamento de caça de lobos cinzentos (A) perseguindo, aproximando e rastreando presas (B-D) perseguindo, assediando e cercando (E) situação estacionária e ataque.



Figura 3.5: Exemplo de ações das alcateias



Fonte: (SETH; CHANDRA, 2016)

Sendo assim seus comportamentos principais são:

Rastreamento, perseguição (aproximando da presa);

Perseguindo, cercando, incitando a presa (até que pare de se mover);

Ataque a presa.

Modelagem da hierarquia social:


Alpha – melhor da geração;

Beta – segundo melhor da geração;

Delta – terceiro melhor da geração;

Ômega – o resto da geração.

Figura 3.6: pirâmide hierárquica das alcateias



Fonte: (DAS; DAS; DAS, 2015)

As etapas do algoritmo estão agrupadas em quatro grupos:

#### A) Cercando a presa

Os lobos cinzentos cercam a presa até que esta pare de se mover. Este pode ser formulado matematicamente como (BIYANTO *et al.*, 2016):

$$\begin{aligned}
 \vec{D} &= |C \cdot \vec{X}_p(t) - \vec{X}(t)| \\
 \vec{X}(t+1) &= \vec{X}_p(t) - \vec{A} \cdot \vec{D} \\
 \vec{A}_1 &= 2\vec{a} \cdot \vec{r}_1 - \vec{a} \\
 \vec{A}_2 &= 2\vec{a} \cdot \vec{r}_1 - \vec{a} \\
 \vec{A}_3 &= 2\vec{a} \cdot \vec{r}_1 - \vec{a} \\
 \vec{C} &= 2 \cdot \vec{r}_2
 \end{aligned} \tag{3.7}$$

#### B) Caçada

A caçada dos lobos cinzentos é comandada pelo alpha, que possui a melhor capacidade de reconhecer a localização do alvo e cerca-la. No entanto no modelo matemático, leva-se em conta tanto o alpha como o beta e delta para a localização e deslocamento, esta formulação é: (BIYANTO *et al.*, 2016)

$$\begin{aligned}
 \vec{D}_\alpha &= |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \\
 \vec{D}_\beta &= |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \\
 \vec{D}_\delta &= |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \\
 \vec{X}_1 &= \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha) \\
 \vec{X}_2 &= \vec{X}_\beta - \vec{A}_2 \cdot (\vec{D}_\beta) \\
 \vec{X}_3 &= \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta) \\
 \vec{X}(t+1) &= \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3}
 \end{aligned} \tag{3.8}$$

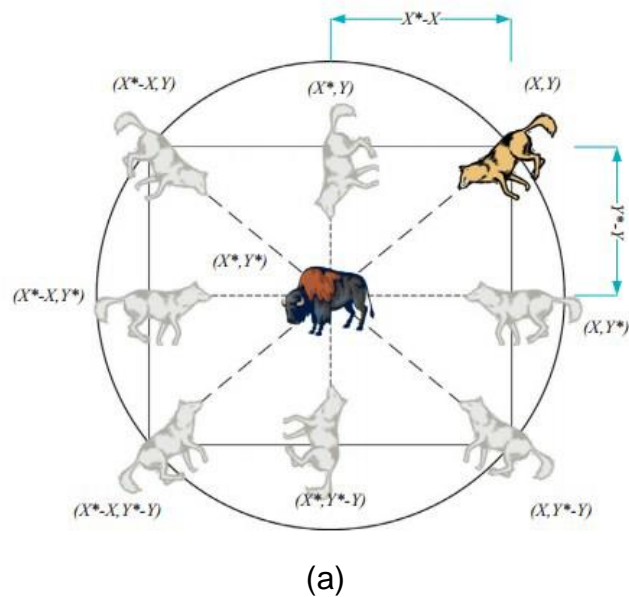
Onde


$\vec{X}_\alpha$	: Posição do Alfa;
$\vec{X}_\beta$	: Posição do Beta;
$\vec{X}_\delta$	: Posição do Delta;
$t$	: Iteração;
$\vec{A}$ e $\vec{C}$	: Coeficiente;
$\vec{X}_p$	: Posição da presa;
$\vec{D}$	: Vetor de presa circundante;
$\vec{a}$	: Componente de avaliação;
$\vec{r}_1$ e $\vec{r}_2$	: Gerado aleatoriamente com intervalo de [0-1].

### C) Atacando a presa

O ataque a presa começa quando o cerco à presa está completo e esta parou de se mover, seja por medo ou confusão. Este ataque no modelo matemático pode ser expresso como o  $A_1$ ,  $A_2$ ,  $A_3$  tendendo a 0, ou seja atacaram a presa.

Figura 3.7: Reprodução em 2D (a) e 3D (b) da técnica de ataque a presa.





(b)

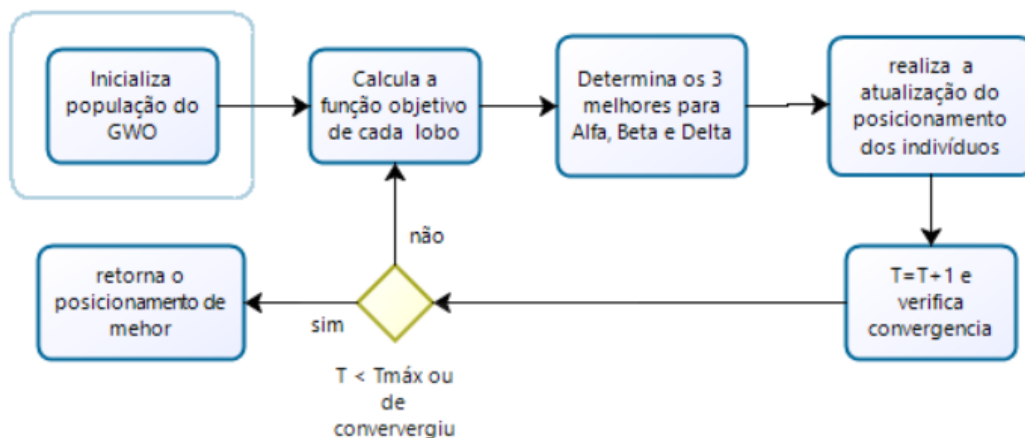
Fonte: (BIYANTO *et al.*, 2016)

#### D) Procurando por uma presa

A procura de uma presa, começa com os alpha, beta e delta divergindo no espaço de busca procurando por uma presa e depois convergindo para cercar e atacar a presa. No modelo isto é feito com o  $A_1$ ,  $A_2$ ,  $A_3$  possuindo módulos maiores que 1, ou seja forçando a não convergir assim explorando a área de busca inicialmente.

O fluxograma pode ser dado por:

Figura 3.8: Adaptação e tradução do fluxograma do algoritmo GWO.



Fonte: Adaptado de (DAS; DAS; DAS, 2015)

### 3.6. Algoritmo Dragonfly (DA)

É um algoritmo com comportamento estocástico que replica o movimento de enxame de partículas existente no comportamento de enxame de libélulas (*dragonfly*). O enxame possui dois objetivos: caçar e migrar (DAELY; SHIN, 2016).

A caça costuma ser realizada em pequenos grupos se dispersando a procura de presas (fonte de comida) na área de busca.

Já a migração, consiste do movimento coordenado de um grande grupo da população, viajando por uma parcela da área de busca.

Estes objetivos são alcançados por meio dos seguintes princípios de funcionamento:

A) Separação: nesta etapa os indivíduos da população se separam para buscar outras áreas, assim como evitam “colidir” entre si e buscando sempre manter um espaço entre os mesmos. É expresso pela formula 3.9.

$$S_i = - \sum_{j=1}^N X - X_j \quad (3.9)$$

onde  $X$  representa a posição atual do indivíduo,  $X_j$  representa a posição de indivíduos vizinhos e  $N$  representa o número de vizinhos (SALAM *et al.*, 2016).

B) Alinhamento: ocorre quando a velocidade e sentido, correspondem entre um grupo de indivíduos. Este pode ser expressado com a seguinte formula:

$$A_i = \frac{\sum_{j=1}^N V_j}{N} \quad (3.10)$$

onde  $V_j$  é a velocidade do indivíduo  $j$  (SALAM *et al.*, 2016).

C) Coesão: quando ocorre a tendência de um grupo convergir para o centro de ação correspondente a este, um centro espacial, sendo visualizado matematicamente com a formula:

$$C_i = \frac{\sum_{j=1}^N X_j}{N} - X \quad (3.11)$$

onde  $X$  é a posição atual do indivíduo,  $N$  é o número de vizinhos e  $X_j$  é a posição do indivíduo  $j$  (SALAM *et al.*, 2016).

D) Atração a uma fonte de comida: tendência do indivíduo de voar em direção a fonte de comida, pode ser expressada por:

$$F_i = X^+ - X \quad (3.12)$$


onde  $X$  é a posição atual e  $X^+$  é a posição da comida (melhor resultado) (SALAM *et al.*, 2016)

E) Fuga ao inimigo: é a tendência do indivíduo voar para longe de um inimigo, sendo dita matematicamente como:

$$E_i = X^- + X \quad (3.13)$$

onde  $X$  é a posição atual e  $X^-$  é a posição do inimigo (pior resultado)

Figura 3.9: Exemplos de comportamento do Dragonfly



Fonte: (MIRJALILI, 2015)

No algoritmo a posição de comida e do inimigo correspondem ao melhor e ao pior fitness, e todos os outros indivíduos respondendo a estes de sua devida forma. O cálculo matemático que simula o deslocamento é dado por: (DAELY; SHIN, 2016)

$$\begin{aligned}\Delta X_i(k+1) &= sS_i(k) + aA_i(k) + cC_i(k) \\ &\quad + fF_i(k) + eE_i(k) + w\Delta X_i(k) \\ X_i(k+1) &= X_i(k) + \Delta X_i(k+1)\end{aligned}\tag{3.13}$$

onde  $w$  é a inércia de movimento da iteração anterior,  $S_i$  é o peso dado para separação,  $A_i$  é o peso dado para alinhamento entre si,  $C_i$ , respectivo para coesão,  $F_i$  é a atração para a comida, e o  $E$  é o de repulsa ao inimigo.

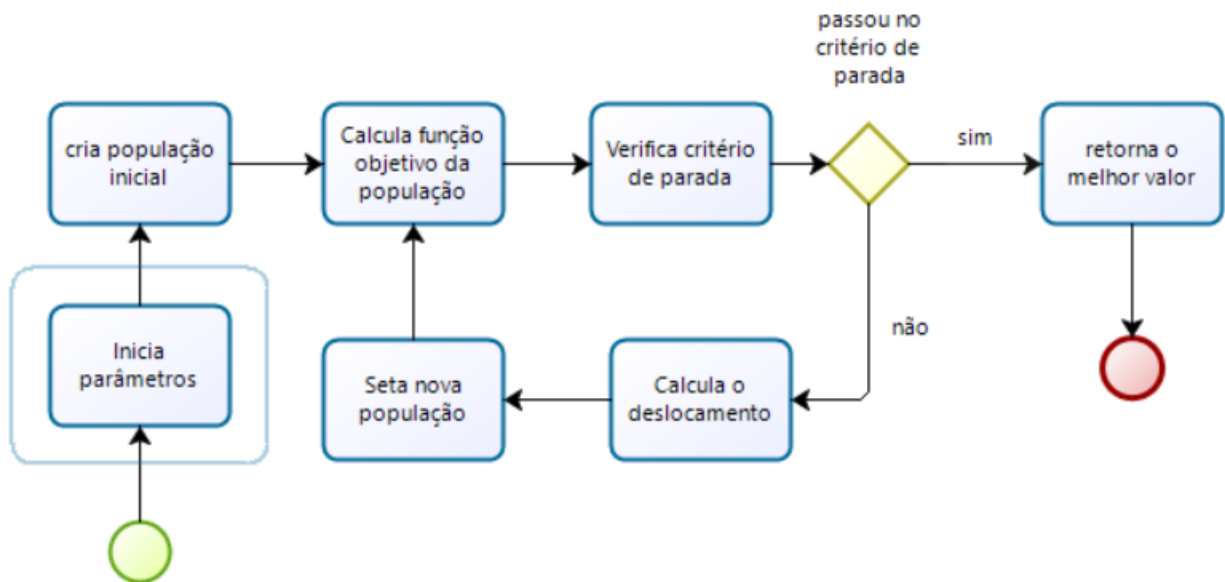
Caso não existam indivíduos próximos o deslocamento é expressado por outra formula, onde este não sofre influência de outros indivíduos na área de busca. Tal formula é expressa matematicamente pela equação: (DAELY; SHIN, 2016)

$$X_i(k+1) = X_i(k) + Lévy(k) \quad (3.14)$$

onde Lévy é definido na equação 3.6.

O fluxograma pode ser dado na figura 3.10.

Figura 3.10: Adaptação e tradução do fluxograma do algoritmo Dragonfly.



Fonte: Adaptado de Fonte: (MIRJALILI, 2015)

### 3.7. Considerações finais do capítulo

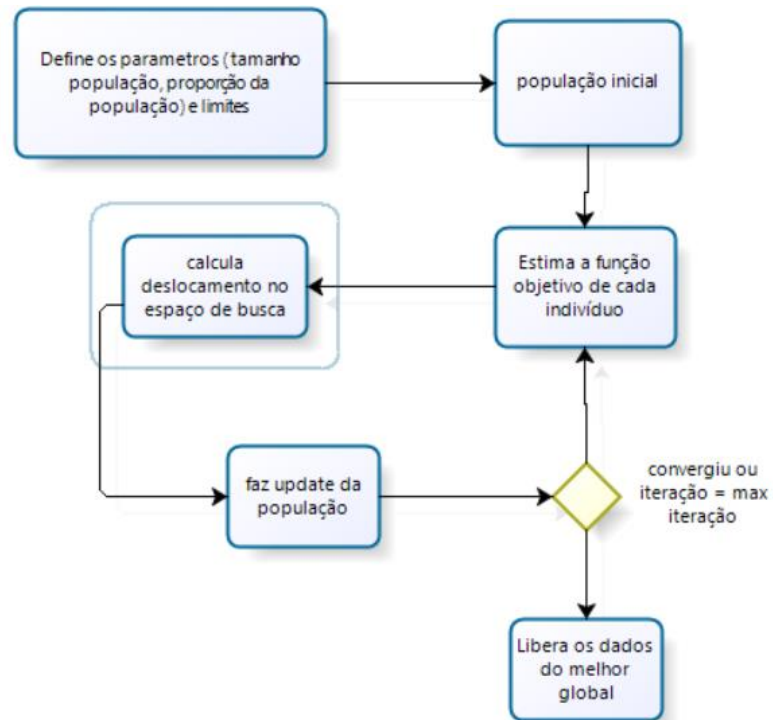
Neste capítulo foram apresentadas as características e a estrutura funcional das seis técnicas meta-heurísticas de otimização consideradas neste trabalho.

Apesar das diferenças conceituais que originaram as diferentes técnicas as mesmas apresentam importantes similaridades das quais pode-se destacar: utilização de população inicial, deslocamento pelo espaço de busca, parâmetros de parada. Sendo assim o que muda efetivamente entre estes, é a forma em como são calculado os deslocamentos, ou seja, a definição da próxima geração.



Com isso, é possível definir um padrão seguido por todos os algoritmos como o apresentado na figura 3.11.

Figura 3.11: Fluxograma comum entre os algoritmos



Fonte: Próprio autor

## 4. Metodologia

Este capítulo trata da determinação dos critérios, formulação e métodos empregados para o processo de alocação de dispositivos FACTS em redes elétricas de potência.

Após a escolha dos tipos de dispositivos FACTS a serem considerados no processo de alocação, é imprescindível a determinação de seus princípios de funcionamento e modelagem associada a fim de bem representar suas características de controle na rede elétrica.

O passo seguinte é a determinação do método de cálculo de fluxo de potência apropriado, considerando o tipo de sistema a ser estudado. Para este trabalho, considerando a aplicação dos controladores FACTS em redes de transmissão, foi utilizado o tradicional método de Newton-Raphson, com a incorporação da representação de controle dos dispositivos FACTS, (TORTELLI, 2010), (ACHA; KAZEMTABRIZI, 2013), (FUERTE-ESQUIVEL; ACHA; AMBRIZ-PÉREZ, 2000), (KAMEL; ABDEL-AKHER; EL-NEMR, 2010).

Além disso, com a escolha dos dispositivos a serem considerados e sua incorporação ao método de cálculo do fluxo de potência, tratou-se da determinação da função objetivo associada ao desempenho dos controladores na rede elétrica e sua implicação nas técnicas meta-heurísticas de otimização consideradas. Assim a função objetivo foi determinada tendo-se em vista uma das principais funções dos controladores que é a melhoria da eficiência de rede elétrica.

Por fim, deve-se determinar o arranjo metodológico que associa a avaliação do desempenho dos controladores FACTS em regime permanente às técnicas meta-heurísticas como definidoras do processo de alocação ótima consideradas neste estudo. Para tanto são destacadas as características de cada uma destas técnicas.

#### 4.1. Escolha dos dispositivos FACTS

Tendo em vista que este estudo é realizado para a alocação de Dispositivos FACTS, a preferência foi pelos da segunda geração. Embora estes tipicamente possuam um custo mais elevado que os da primeira geração, foram escolhidos em função de apresentarem, devido à evolução tecnológica, um efeito de controle mais avançado sobre a rede elétrica de transmissão.

Sendo assim serão utilizados no estudo os três dispositivos fundamentais da segunda geração: o STATCOM, o SSSC e o UPFC.

#### 4.2. Modelagem dos dispositivos FACTS no fluxo de potência

Considerando que o método de cálculo de fluxo de potência utilizado neste trabalho foi o tradicional Método de Newton-Raphson, a seguir são descritas as adaptações feitas no mesmo para incorporar a representação dos dispositivos FACTS no processo de solução.

Nesse sentido, considerando que esse método se baseia na solução de sucessivos problemas lineares descritos pela equação (4.1), onde as submatrizes  $H$ ,  $M$ ,  $N$  e  $L$  constituem a matriz Jacobiana do problema e representam as derivadas parciais das injeções de potência nodal ( $P$  e  $Q$ ) com relação às variáveis de estado ( $\theta$  e  $V$ ) (TINNEY;HART, 1967) tal que:

$$\begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = \begin{bmatrix} H & N \\ M & L \end{bmatrix} \begin{bmatrix} \Delta \theta \\ \Delta V \end{bmatrix} \quad (4.1)$$

As próximas subseções tratam das modificações feitas na matriz Jacobiana para incorporar o efeito de controle dos dispositivos FACTS.

#### 4.2.1. STATCOM

Neste modelo, não ocorre muita mudança na forma de cálculo da Matriz Jacobiana, inclusive não aumentando a dimensão da mesma.

Tendo em vista que a ação de controle do dispositivo apenas atua sobre a potência reativa, como indicado pela equação (4.2), a modificação na matriz Jacobiana implica em substituir a variável de estado associada à magnitude da tensão de barra ( $V_k$ ), que passa a ser especificada (controlada), pela magnitude da tensão do controlador ( $V_{stt}$ ), como indicado na equação (4.3), com o respectivo reflexo nos elementos da matriz Jacobiana. (TORTELLI, 2010)

$$Q_{stt} = -V_{stt}^2 \cdot B_{stt} + V_{stt} \cdot V_k \cdot B_{stt} \quad (4.2)$$

$$\begin{bmatrix} \vdots \\ \Delta P_k \\ \Delta Q_{stt} \\ \vdots \end{bmatrix} = \begin{bmatrix} \ddots & & & \\ & H & 0 & \\ & 0 & \frac{\partial Q_{stt}}{\partial V_{stt}} & \\ & & 0 & \ddots \end{bmatrix} \begin{bmatrix} \vdots \\ \Delta \theta_k \\ \Delta V_{stt} \\ \vdots \end{bmatrix} \quad (4.3)$$

onde:  $B_{stt}$  é a impedância característica do controlador.

#### 4.2.2. SSSC

Para incorporação do SSSC, a dimensão da matriz Jacobiana é aumentada. São adicionados mais duas colunas e duas linhas para cada dispositivo. Os parâmetros de controle acrescentados são correspondentes ao fluxo de potência tanto ativo como reativo controlados pelo dispositivo, de acordo com o indicado pelas equações (4.3) e (4.4) (TORTELLI, 2010). Nesta lógica o fluxo de potência fica fixo (controlável), e o que altera neste caso são as novas variáveis de estado no caso, o ângulo ( $\theta_{sssc}$ ) e a magnitude ( $V_{sssc}$ ) da tensão do controlador.





### 4.3. Definição da função objetivo

A definição da função objetivo de problemas relacionadas à alocação de dispositivos de controle é usualmente associada à melhoria da eficiência e/ou segurança operativa do sistema de potência. Sendo assim existem neste sentido duas funções objetivo comumente empregadas: redução do desvio da magnitude de tensão de barra, como indicado na equação (4.10), e redução das perdas totais do sistema, indicado pela equação (4.11).

Desvio de tensão

$$\text{Desvio Tensão} = \sum_{i=1}^n (V_i - V_{ref})^2 \quad (4.10)$$

onde  $V_i$  é a tensão em cada barramento,  $V_{ref}$  é a tensão de referência e  $n$  é o número de barras do sistema.

Perdas ativas totais

$$\text{Perdas totais} = \sum_{i=1}^n \text{perdas}_i \quad (4.11)$$


onde  $n$  é o número de linhas de transmissão.

Neste trabalho optou-se portanto, por relacionar a alocação dos dispositivos com o objetivo de somente minimizar as perdas de potência ativa do sistema. Isto implica na diminuição da utilização dos geradores do sistema e otimização na circulação da potência na rede elétrica. Assim, com esta métrica, fica mais evidente a relação com os custos de operação de um determinado sistema.

#### 4.4. Consideração às condições de operação – Patamares de carga

No presente trabalho, são considerados a possibilidade de representar as diferentes condições de carga de determinado sistema em três diferentes patamares: Carga Leve, Carga Média e Carga Pesada. Os patamares são definidos a partir da discretização das médias de consumo diário em três intervalos de consumo, como indicado pela Figura 4.1. Assim, são médias de carga, cujo objetivo é simplificar o comportamento de consumo de sistema, mas ao mesmo tempo considerar o efeito de variação de consumos significativos nos dispositivos de controle atuando na rede elétrica.

Figura 4.1: Exemplo da representação de patamares



Fonte: (FERREIRA, 2015)

Conforme é mostrado na figura 4.1, cada cor representa um intervalo de consumo distinto. Tal comportamento é então normalizado em apenas três níveis distintos, representando assim a carga diária de maneira simplificada. Busca-se com isso reduzir o esforço computacional necessário para executar estudos de grande porte como o que caracteriza problemas de alocação de dispositivos.



#### 4.5. Escolha de Meta-heurísticas

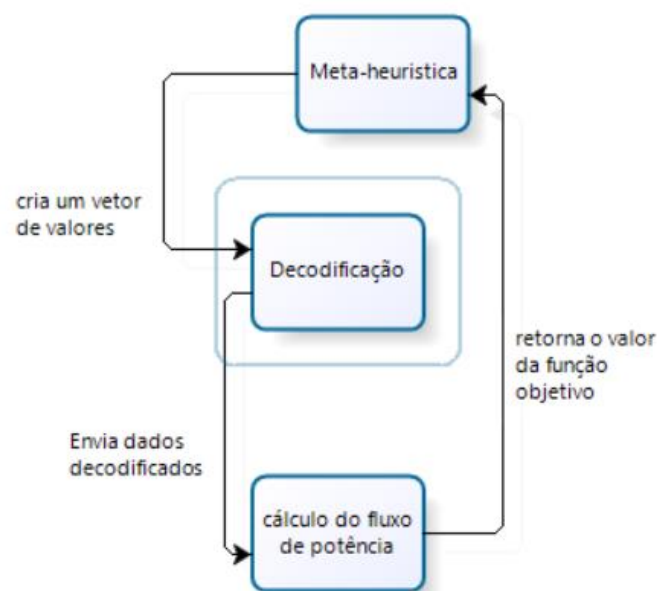
Quanto aos algoritmos utilizados, serão utilizados todos os indicados no início deste documento que são: GA, Dragonfly, GWO, CROW, ORCS, SSO, pois além de possuírem características em comum, o estudo visa também a comparação e eficácia entre estes.

As características em comum se baseiam na comparação com o mais estudado, no caso o GA. Para tanto, todos os outros necessitam então ter o mesmo tamanho de população, o mesmo critério de parada; entre os estudados, todos estes podem ser executados equiparavelmente com o GA.

No entanto para tal, não basta delimitar os algoritmos, deve-se impor ordem de fazer com que todos estes tenham saídas equivalentes, pois existe a necessidade de um algoritmo intermediário para a conversão de uma simples matriz com uma única linha para a organização necessária para que o fluxo de potência possa ser executado da forma correta.

Sendo assim todo o estudo realizado neste documento visa o desenvolvimento e comparação entre o GA e os demais (Dragonfly, GWO, CROW, ORCS, SSO).

Figura 4.2: Representação mais simples da movimentação dos dados



Fonte: O autor

#### 4.5.1. Codificação das Variáveis

Esta seção diz respeito a como os dados para dos dispositivos FACTS foram codificados para a realização deste trabalho.

##### 4.5.1.1. STATCOM

Os parâmetros pertinentes à implantação do dispositivo FACTS do tipo STATCOM, são definido como:

- Posicionamento: número da barra onde será alocado o dispositivo;
- Tensão de controle: valor da tensão da barra controlada.

Existem outros parâmetros indiretos que devem ser considerados, tais como os limites impostos na atuação do dispositivo:

- Variação máxima da magnitude de tensão: neste trabalho considerou-se 0.05 pu;
- Limitação das barras (exclui-se as que possuem geradores ou compensadores).

##### 4.5.1.2. SSSC

Para a codificação do dispositivo SSSC os parâmetros associados são:

- Posicionamento: número da LT onde será alocado o dispositivo.
- Fluxo de potência ativa controlado;
- Fluxo de potência reativa controlado.

##### 4.5.1.3. UPFC

Quanto à forma de codificação do UPFC, este possui os mesmos parâmetros de controle do STATCOM (compensador shunt) e do SSSC (compensador série) juntos. Assim, tanto os parâmetros quanto as limitações são da mesma natureza:

- Posicionamento: número da LT onde será alocado o dispositivo (o sinal indica a barra de tensão controlada);
- Variação máxima da magnitude de tensão: neste trabalho considerou-se 0.05 pu;
- Limitação das barra candidatas (exclui-se as que possuem geradores ou compensadores);
- Limitação das linhas candidatas (linhas mais carregadas).

#### 4.5.2. Outras aspectos pertinentes quanto à codificação

Com relação à ordenação dos valores de posicionamento tanto da barras quanto das linhas de transmissão, este quesito é importante para delimitar a área de busca do algoritmo, pois nem todas as barras são passíveis de terem um controlador STATCOM, como as barras do tipo PV, que já possuem o controle de tensão.

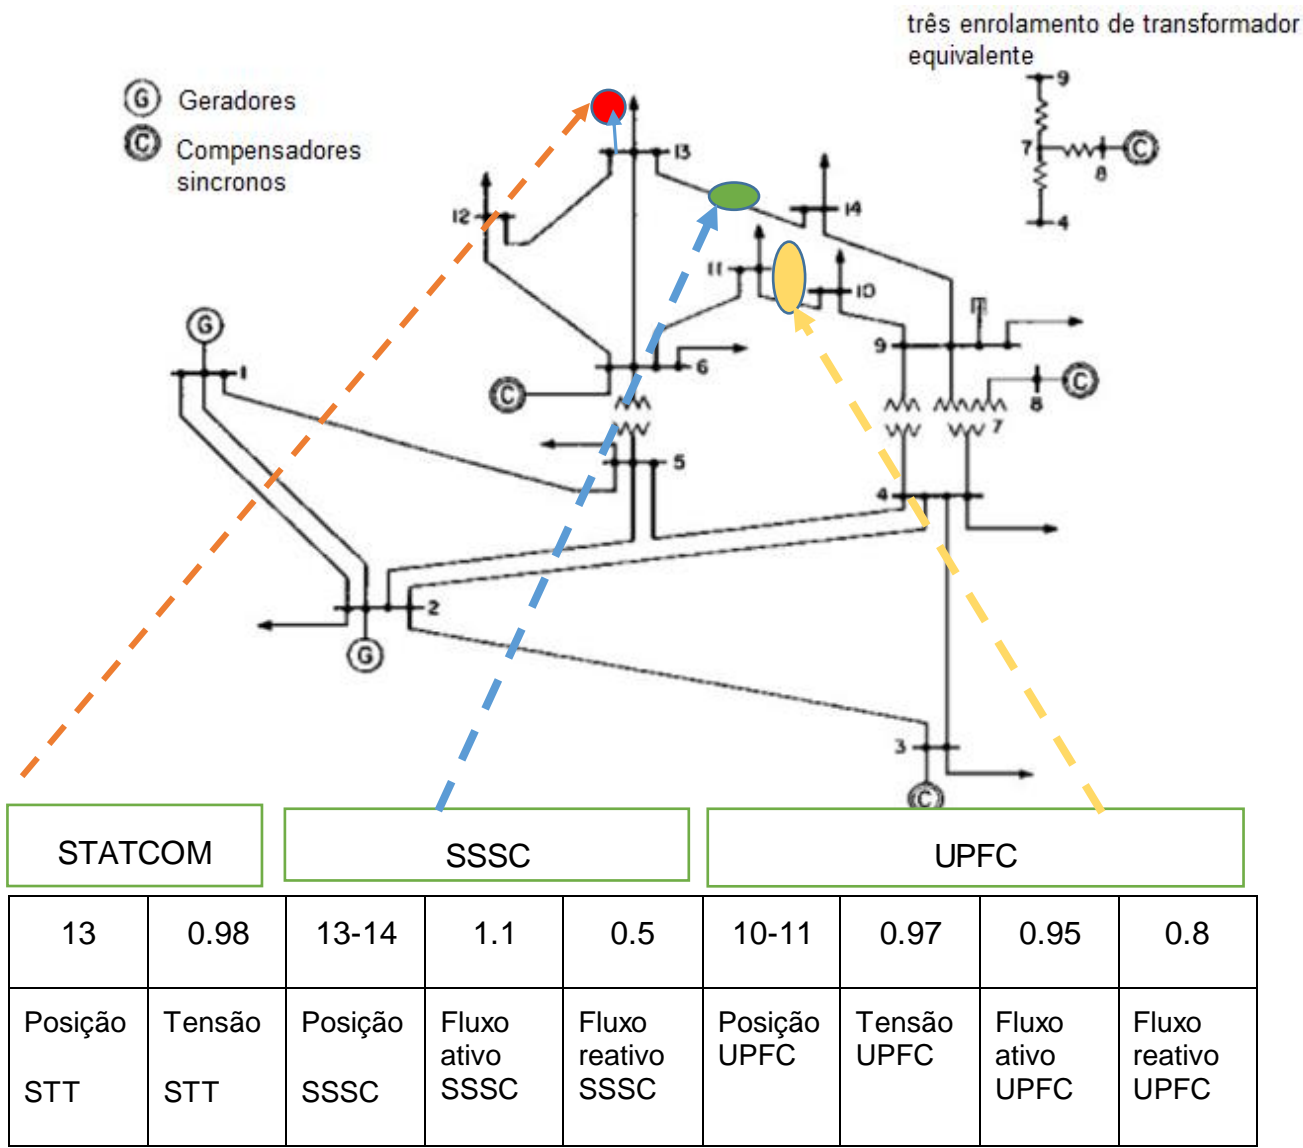
Quanto aos controladores série, também as linhas de transmissão candidatas a recebê-los foram ordenadas de acordo com o nível de fluxo de potência ativa observado no cenário anterior à instalação do qualquer dispositivo. Essa ordenação foi considerada na definição do conjunto das barras candidatas a receberem controladores série (SSSC e UPFC).

Estes passos ajudam a reduzir o esforço computacional do processo de busca, pois restringe-se o espaço das barras/linhas candidatas àquelas com maior potencial para receber os controladores, reduzindo assim o tempo de simulação.

#### 4.5.3. Exemplo de codificação

Considerando a alocação simultânea de cada um dos tipos de controlador tratados neste trabalho, tem-se o *string* (indivíduo) indicado pela Figura 4.3, que contém os parâmetros a serem decodificados para incorporação ao programa de cálculo de fluxo de potência.

Figura 4.3: Exemplo de codificação

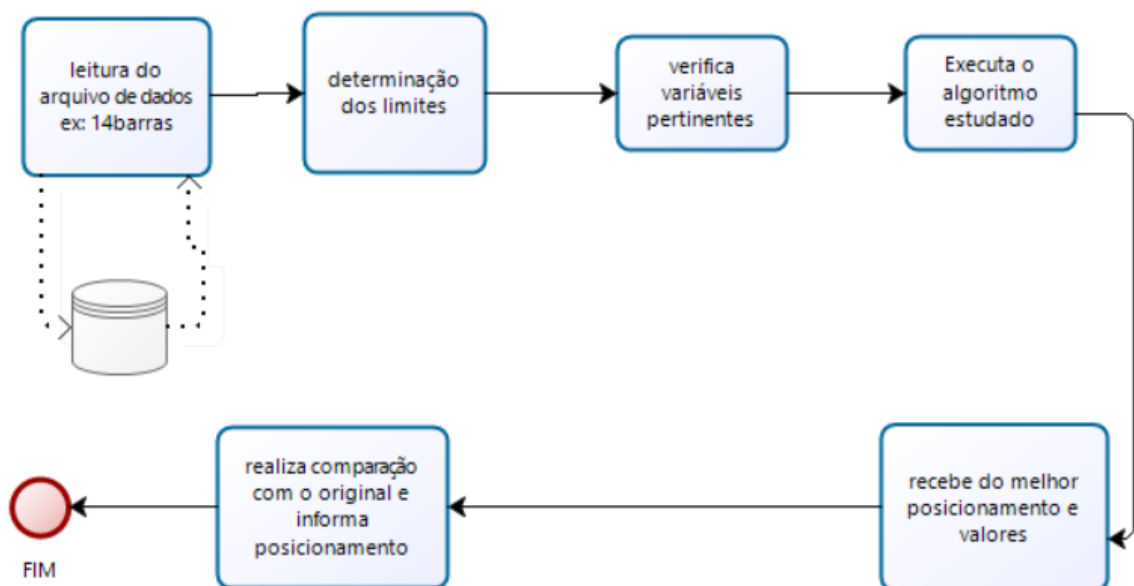


Fonte: O autor

#### 4.6. Fluxograma

Na figura 4.4, é demonstrado o princípio básico de funcionamento geral do algoritmo. Inicialmente há a leitura dos casos de estudo, como por exemplo o caso 14 do IEEE, seguido a este existe a determinação dos limites, onde neste caso ocorre a conversão dos posicionamentos tanto dos barramentos quanto das linhas de transmissão. Esta conversão existe para facilitar a área de busca do algoritmo, eliminando possibilidades como por STATCOM em barramentos PV. Outro fato importante neste é a especificação dos limites, tanto dos dispositivos quanto para os próprios algoritmos de meta-heurística.

Figura 4.4: fluxograma do programa principal/inicial



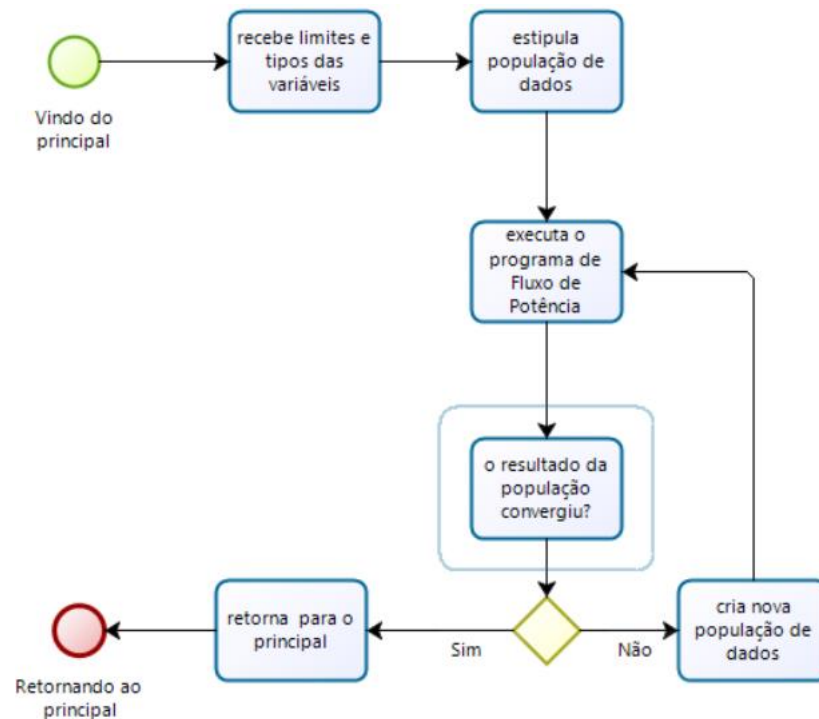
Fonte: O autor

Já a verificação de variáveis tem importância tanto no número de patamares que se está executando quanto no número de dispositivos de cada tipo a serem executados com o algoritmo.

A parte “executa o algoritmo estudado” é a ligação com o fluxograma demonstrado na figura 4.5. Já as partes seguintes são a obtenção tanto dos valores encontrados para posicionamento quanto para capacidade, assim como a melhora fornecida, ainda assim

é executado um cálculo direto de fluxo de potência para validação do resultado e é realizado uma comparação com o valor original para se descobrir a melhora percentual do encontrado.

Figura 4.5: fluxograma genérico dos programa meta-heurísticas

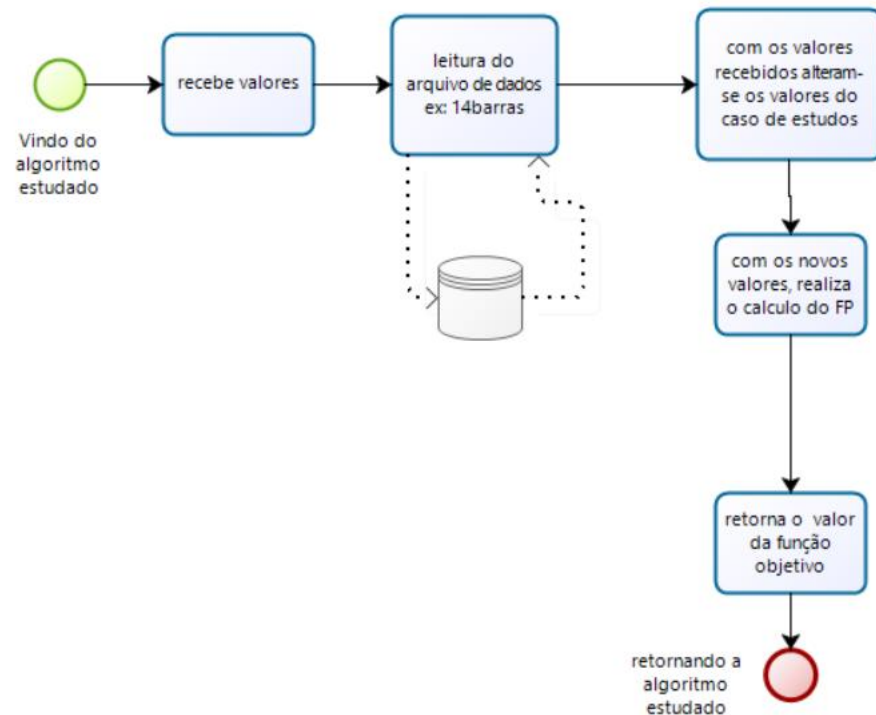


Fonte: O autor

Conforme demonstrado na figura 4.5, o algoritmo de meta-heurística recebe as informações quanto aos limites e tipos de variáveis, isto é, se são do tipo variáveis de tamanho de população, controle geral ou limites para as variáveis a serem criadas pelo algoritmo meta-heurística empregado. Partindo deste passo, o algoritmo cria a população inicial tendo como base o controle do aleatório, o tamanho da população.

Seguindo, o algoritmo segue para o cálculo de fluxo de potência com as informações das populações criadas. Por meio deste, é obtida a informação pertinente, perda total, por meio desta o algoritmo verifica se os resultados obtidos se caracterizam com os critérios de parada, caso sim, retorna para o principal, caso negativo, este por meio de seus cálculos diferenciados entre cada tipo de algoritmo, é criada uma nova população, reiniciando a procura de resultados compatíveis com os critérios de parada.

Figura 4.6: fluxograma da preparação dos dados e o cálculo do fluxo de potência.



Fonte: O autor

A figura 4.6 apresenta o fluxograma para executar o fluxo de potência após a criação de uma dada população por meio dos algoritmos de meta-heurística. Os passos iniciais são a obtenção dos valores das populações, a leitura dos dados dos casos estudados, como o 14 barras. Conforme estes são recebidos, é exigido uma reconversão dos dados tabulados para a disposição do formato dos 14 barras, por meio desta, é corrigida o posicionamento para o real, como os dados do próprio caso, são modificados para se adequar a existência de dispositivos FACTS na rede estudada.

Por meio destes valores, é calculado o fluxo de potência, retornando para o passo anterior o valor da função objetivo, no caso as perdas totais.

## 5. Simulações e Resultados

Neste capítulo serão apresentados resultados das simulações realizadas, especificando como estas foram realizadas, assim como a exibição da comparação entre os algoritmos de meta-heurística empregados

### 5.1. Características do ambiente de simulação.

Tendo em vista que as diferentes técnicas de alocação também foram avaliadas em termos de desempenho computacional, é importante indicar o ambiente de simulação utilizado para a realização dos testes. As especificações de software e hardware utilizados estão listadas a seguir.

- Software: Windows 7 (KB2952664) e Matlab versão R2015a 64-bit;
- Hardware: AMD Phenom II x6 1090T Black edition seis núcleos de 3.2 GHz (usando over para 3.6 GHz) e 12 GB de memória RAM 1333MHz.

Estas especificações são importantes de serem descritas, pois o trabalho ao ser executado em outro ambiente, mesmo que os resultados obtidos sejam os mesmos, o tempo utilizado pelo mesmo poderá variar.

### 5.2. Casos teste

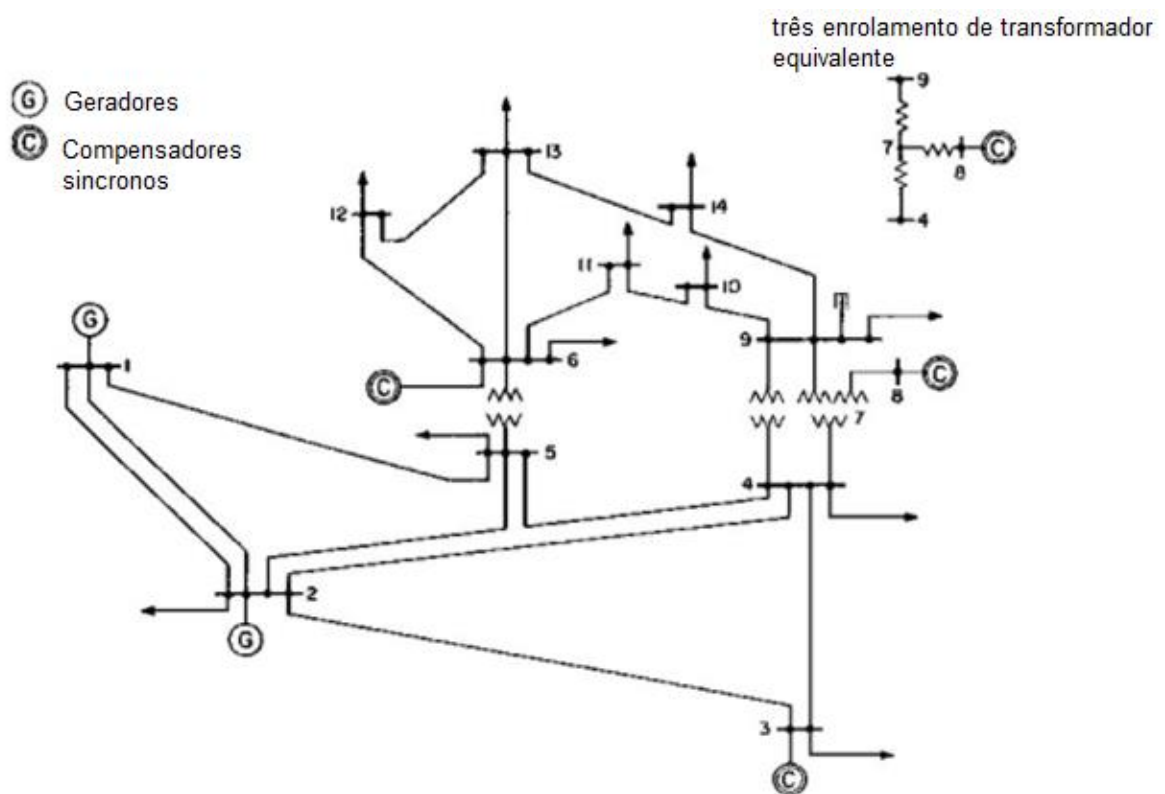
Para o desenvolvimento das avaliações e validação do estudo de alocação dos dispositivos FACTS, foram considerados dois sistemas teste: o sistema teste de 14 barras e o de 118 barras, ambos do IEEE [Washington.edu].

E para a avaliação são utilizados três casos teste, o 14 barras com três patamares, o 30 barras e o 57 barras. Portanto os casos de estudo apresentados neste trabalho são os seguintes:



- Sistema IEEE com 14 barras com um único patamar de carga;
- Sistema IEEE com 14 barras considerando três patamares de carga;
- Sistema IEEE com 118 barras com um único patamar de carga.
- Sistema IEEE com 30 barras com um único patamar de carga no apêndice.
- Sistema IEEE com 57 barras com um único patamar de carga no apêndice.

Figura 5.1: Exemplo de caso teste, caso com 14 barras



Fonte: (WASHINGTON, 1996).

### 5.3. Premissas comuns a todas as simulações

Todas as simulações foram realizadas adotando-se premissas comuns para que as comparações possam ser realizadas de forma mais justa entre si. Como o GA está sendo usado como algoritmo de referência base de comparação, as premissas foram adotadas a partir deste, como indicado a seguir:

- Paralelismo: Visando tanto utilizar todos os recursos computacionais, quanto a obtenção do resultado com o menor tempo, todos os algoritmos foram paralelizados, ou seja existem seções nestes em que com o suporte de paralelismo do ambiente Matlab, permite que sejam executados as obtenções dos fitness das populações, de forma simultânea sem que ocorram inconsistências e erros típicos do processo.

- Tamanho de população: Como um dos critérios é a de possibilitar uma comparação equiparável ao GA a todos os algoritmos, todos possuem população do mesmo tamanho permitindo que se possa verificar eficiência entre estes, tendo como base o tamanho de população recomendada pelo GA.

- Critérios de parada: Todos os algoritmos compartilham dos mesmos critérios de parada, como número máximo de gerações, e critérios de convergência tais como diferenças entre as gerações.

- Sementes para geração de números aleatórios: Para que fosse possível se verificar que com uma mesma população, e um mesmo transcorrer do desenvolvimento da execução, foi estabelecido a utilização de controle de randômico, ou seja atribuir uma semente a este de forma controlada, sendo assim todos os algoritmos recebem as mesmas sementes, que geram no caso as mesmas populações iniciais. Outro fator deste, é que permite a reprodução sucessiva de teste que obterão no caso os mesmos resultados.

- Limites: Todos os algoritmos possuem os mesmos limites impostos quanto a determinação de quantos dispositivos FACTS são considerados para alocação simultânea, assim como os destes dispositivos.

## 5.4. Aferição das técnicas de otimização

Estas simulações servem para confirmar a capacidade dos diferentes algoritmos de meta-heurística de obterem resultados adequados de alocação frente aos mesmos critérios estabelecidos. Assim, para essa avaliação foram considerados apenas um único controlador FACTS em cada simulação.

Da mesma forma para a execução destas simulações, são utilizadas tanto os caso 14 barras quanto o 118 barras, ambos com um único patamar.

Tendo em vista somente a validação da capacidade dos algoritmos, foram realizados somente 20 simulações para cada tipo de controlador, e em cada uma foi utilizada uma população de 100 indivíduos. O critério de parada foi o de número máximo de gerações, estipulado em 80, visto que o objetivo neste é somente de verificar se os resultados obtidos são condizentes entre si.

Para cada uma das técnicas meta-heurísticas (CROW, Dragonfly, GA, GWO, ORCS, SSO), foi avaliada a coerência da alocação de cada dispositivo com relação à posição e a melhora da função objetivo além da avaliação do tempo computacional dispendido no processo da alocação

A fim de facilitar a comparação dos resultados, no caso da melhora da função objetivo (perdas ativas), foi considerada a melhora relativa percentual em relação ao obtido na rede elétrica sem a alocação de nenhum dispositivo (caso base).

### 5.4.1. Sistema teste de 14 barras

Nesta seção são apresentados resultados de simulações, considerando as condições descritas acima, utilizando o sistema teste de 14 barras com um único patamar de carga.

#### 5.4.1.1. Posicionamentos obtidos

Conforme demonstrado na tabela 5.1, todos os resultados obtidos quanto a alocação indicada para os controladores foram iguais, demonstrando que todos os algoritmos testados tem capacidade de convergir para o mesmo posicionamento, tendo assim sua capacidade aferida quanto à coerência no processo de alocação. Em apenas duas situações, GWO-SSSC e GA-UPFC, houve alguma variação na posição indicada para alocação, dentre as 20 simulações realizadas.


Tabela 5.1: Alocação e frequência – Sistema teste 14 barras com um patamar de carga

FACTS	GA	CROW	GWO	ORCS	SSO	DA
STATCOM	Barra 9 100%	Barra 9 100%	Barra 9 100%	Barra 9 100%	Barra 9 100%	Barra 9 100%
SSSC	LT 2-4 100%	LT 2-4 100%	LT 2-4 90%	LT 2-4 100%	LT 2-4 100%	LT 2-4 100%
UPFC	LT 2-4 80%	LT 2-4 100%	LT 2-4 100%	LT 2-4 100%	LT 2-4 100%	LT 2-4 100%

Fonte: O autor

A figura 5.2 apresenta a melhoria observada na redução das perdas ativas para a melhor alocação de cada um dos dispositivos FACTS. Pode-se perceber uma redução da ordem de 20% quando da alocação de um SSSC ou de um UPFC, em função de serem os dispositivos que apresenta funcionalidades diretamente associadas ao controle do fluxo ativo.

Figura 5.2: Perdas ativas (em pu)

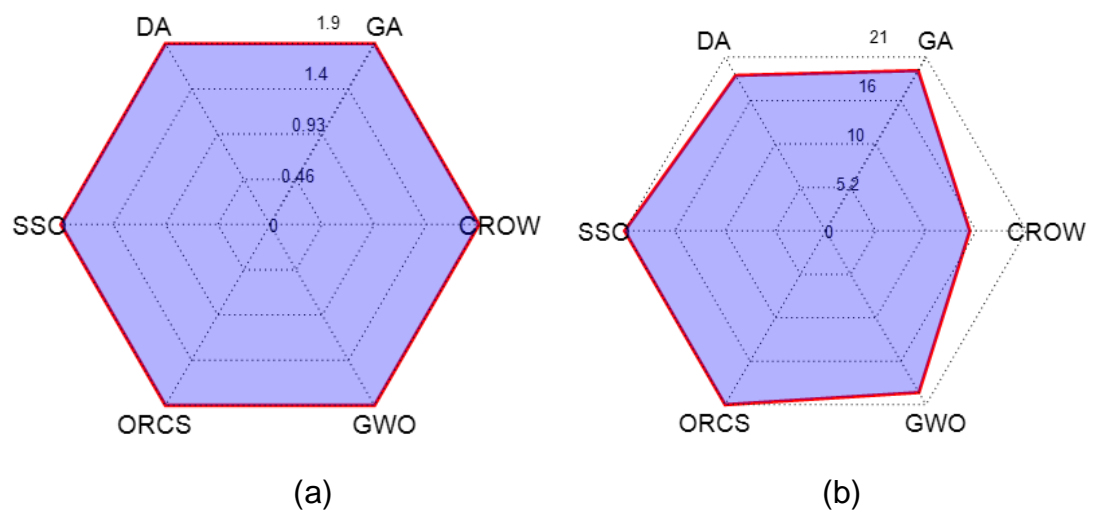



(1) sem FACTS, (2) STATCOM, (3) SSSC e (4) UPFC

Fonte: O autor

#### 5.4.1.2. Avaliação quanto à melhora da função objetivo

Figura 5.3: Função objetivo: melhora percentual média





(c)

(a) STATCOM, (b) SSSC e (c) UPFC

Fonte: O autor

Como é possível visualizar na figura 5.3, todos os algoritmos obtiveram o mesmo resultado geral para o STATCOM, indicando que foram efetivos no quesito de encontrar o melhor resultado.

Com relação a alocação do SSSC e UPFC, levando-se em conta que o GA é o algoritmo usado como referência, podemos concluir que, neste caso teste, a maioria dos algoritmos se saíram melhores quando comparados ao GA, sendo que apenas o algoritmo CROW tenha fornecido repostas inferiores, o que influenciou o gráfico a sair do formato simétrico. Mais especificamente para alocação do UPFC, é possível observar que os algoritmos GWO, ORCS, SSO e Dragonfly apresentaram resultados muito parecidos, com nenhuma variação significativa. Outra característica foi um baixo desvio padrão para este.

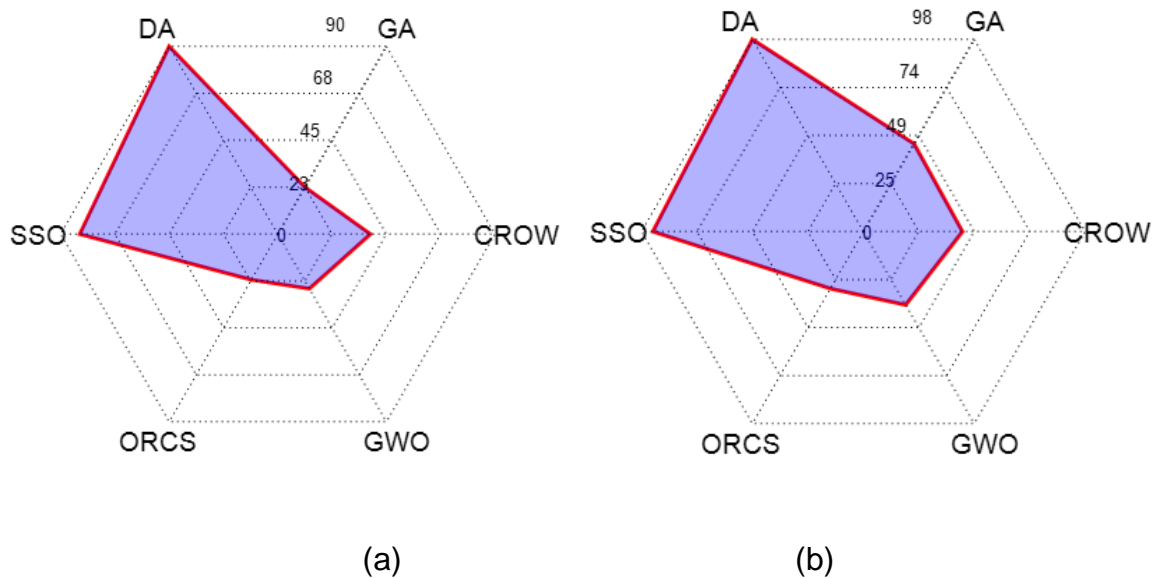
Com relação a diferenças verificadas na melhora percentual obtida para cada um dos algoritmos para cada um dos dispositivos alocados, isto se deve ao fato de que, embora os posicionamentos sejam os mesmos, os parâmetros de controle determinados junto com o processo de alocação para estes dispositivos podem não ser exatamente os mesmos, influenciando assim o resultado final obtido.


#### 5.4.1.3. Tempo médio de simulação

Considerando que nesta etapa todas as técnicas meta-heurísticas avaliadas foram forçadas a processar as 80 gerações, definidas como único critério de parada, e com base na figura 5.4 é possível notar o relativo baixo consumo de tempo para o GA, ORCS e GWO, com um ligeiro aumento para o CROW ao passo que o SSO e o DA consumiram em média mais tempo do que os outros.

Já com relação ao tempo de simulação médio para o posicionamento de um SSSC e de um UPFC, considerando os mesmos critérios de parada, os algoritmos em geral necessitaram de mais tempo. É possível destacar ainda que os algoritmos SSO, DA, CROW e ORCS não tiveram um crescimento de tempo tão grande quanto o GA e GWO quando comparado ao tempo necessário para alocação de um STATCOM.

Figura 5.4: Tempo médio em segundos de simulação para alocação de um único controlador





(c)

(a) STATCOM, (b) SSSC, (c) UPFC

Fonte: O autor

#### 5.4.2. Sistema teste com 118 barras

Nesta seção são apresentados resultados das simulações utilizando o sistema teste de 118 barras considerando um único patamar de carga e alocação de um único dispositivo FACTS de cada vez sob as mesmas condições observadas na seção anterior.

##### 5.4.2.1. Posicionamentos obtidos

É importante observar que devido ao tamanho e maior complexidade do sistema de 118 barras, o mesmo é muito mais sujeito a ótimos locais no processo de alocação do que o sistema de 14 barras.



Tabela 5.2: Alocação – Sistema teste de 118 barras


FACTS	GA	CROW	GWO	ORCS	SSO	DA
STATCOM	B 95 90%	B 95 100%	B 95 100%	B 95 100%	B 95 100%	B 95 100%
	B 94 10%	-----	-----	-----	-----	-----
SSSC	LT 49-66 50%	LT 42-49 80%	LT 89-92 50%	LT 42-49 100%	LT 42-49 50%	LT 49-66 50%
	LT 89-92 30%	LT 89-90 10%	LT 42-49 20%	-----	LT 49-66 40%	LT 42-49 40%
UPFC	LT 26-30 30%	LT 42-49 50%	LT 89-92 80%	LT 42-49 80%	LT 42-49 50%	LT 42-49 70%
	LT 49-66 30%	LT 26-30 40%	LT 26-30 10%	LT 49-66 20%	LT 89-92 30%	LT 49-66 20%

Fonte: O autor

No entanto, pela tabela 5.2 é possível observar que houve uma grande convergência entre os resultados obtidos pelas diferentes heurísticas. Especialmente no caso da alocação do STATCOM, apenas duas simulações com o AG produziram resultados diferentes dos demais. Já na alocação do SSSC e do UPFC os resultados obtidos indicaram uma maior diversidade de alocações, mas mesmo assim é possível perceber que existe um padrão nas posições indicadas, visto que as LT 42-49 e LT 46-66 tem maior frequência.

A figura 5.5 apresenta a melhoria observada na redução das perdas ativas para a melhor alocação de cada um dos dispositivos FACTS aplicados ao sistema de 118 barras. Pode-se perceber uma redução da ordem de 5% quando da alocação de um SSSC ou de um UPFC.

Figura 5.5: melhores resultados em pu dos dispositivos (em pu)




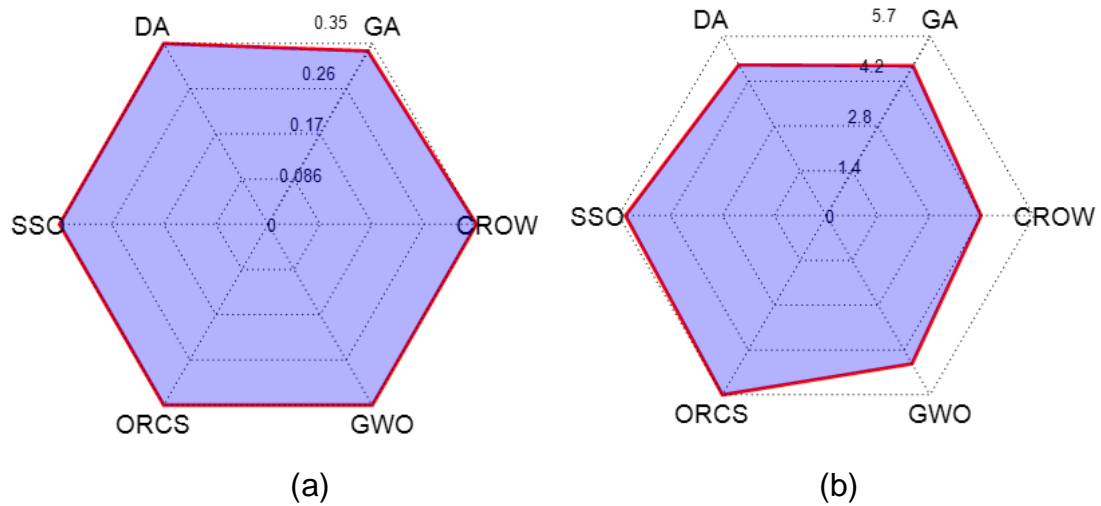
(1) original, (2) STATCOM, (3) SSSC e (4) UPFC

Fonte: O autor

#### 5.4.2.2. Melhora percentual

Como é possível visualizar na figura 5.6, todos os algoritmos obtiveram o mesmo resultado geral, incluindo a mesma média, ou seja todos foram eficientes no quesito de encontrar o melhor resultado comparativamente. A única divergência é observada no comportamento do GA, em que existem dois resultados de posicionamento diferente, menores que os demais.

Figura 5.6: Função objetivo: melhora percentual média



(a) STATCOM, (b) SSSC, (c) UPFC  
Fonte: O autor

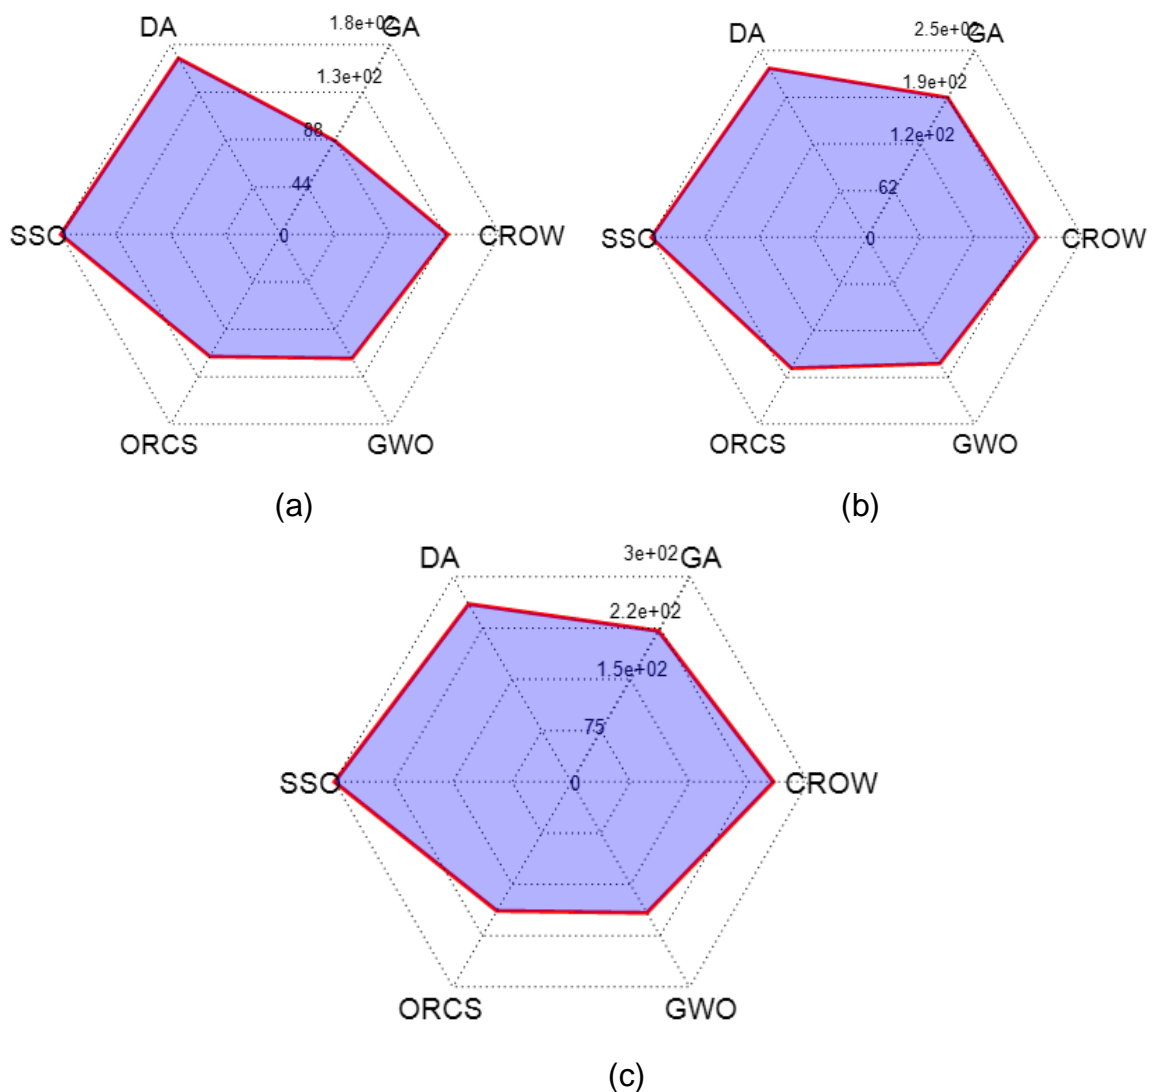
Já no caso do SSSC, os resultados tiveram algumas divergências. Quanto a média de cada um, pode-se perceber que neste caso teste a maioria dos algoritmos saíram-se melhores quando comparados ao GA.

Quanto ao observado na alocação do UPFC, o algoritmo CROW apresentou resultados muito semelhantes ao obtido com o GA. Os demais algoritmos apresentaram resultados melhores, com médias superiores aos do GA.

### 5.4.2.3. Tempo de simulação

Com base na figura 5.7, com relação a alocação do STATCOM, é possível notar que os algoritmos SSO e DA necessitaram de mais tempo que os algoritmos ORCS, GWO e CROW, sendo que o GA foi o que apresentou o menor tempo médio de simulação.

Figura 5.7 - Tempo médio de simulação para alocação de um único controlador



(a) STATCOM, (b) SSSC, (c) UPFC

Fonte: O autor

De forma semelhante ao tempo do STATCOM, para o tempo de alocação do SSSC, os algoritmos SSO e Dragonfly levaram mais tempo para executar todas as 80 gerações. Além disso, é possível perceber que, exceto o GA, que teve um grande crescimento do tempo de execução, todos os demais algoritmos tiveram aumento de proporcionalmente menor em comparação, a alocação do STATCOM praticamente iguais. No caso do UPFC, o aumento relativo do tempo para todos os algoritmos foi praticamente o mesmo para todos.

#### 5.4.3. Considerações quanto à aferição das técnicas de otimização

Com base nos dados obtidos mostrados nessa seção, é possível observar que os algoritmos possuem capacidade de convergir para os mesmos posicionamento. No entanto para alguns casos como na alocação dos dispositivos FACTS dos tipos SSSC e UPFC, os resultados em termos de melhoria apresentaram variantes, estas importantes para determinar se o algoritmo foi eficiente. Assim, tanto para o sistema de 14 barras quanto para o de 118 barras, na maioria das vezes os algoritmos obtinham melhorias na função objetivo igual ou superior ao algoritmo base de comparação, o GA. Nos poucos caso em que foram encontrados resultados inferiores, estes foram muito próximos aos obtidos pelo GA.

Quanto ao quesito tempo de simulação, observa-se uma grande variação, inicialmente porque foi obrigado que fossem executados sem nenhum critério de parada usual, forçando assim que todos os algoritmos percorressem todas as gerações. Sendo assim, os que utilizaram mais tempo neste caso, são os que necessitam de mais tempo para executar cada geração, e, nesse sentido, os algoritmos SSO e Dragonfly não se mostraram eficientes.

## 5.5. Avaliação de desempenho

Nesta seção são apresentados resultados de simulações com o objetivo principal de evidenciar o desempenho na alocação dos três tipos de dispositivos FACTS, pelas diferentes meta-heurísticas, tendo como parâmetro de base o desempenho do GA. Portanto, visando uma avaliação equilibrada e a precisão passou a ser utilizada como critério de parada. Assim, as simulações são executadas considerando os três tipos de FACTS simultaneamente e o limite máximo de gerações não será obrigatoriamente atingido. Além disso, o conjunto de simulações a ser executado para cada caso foi ampliado para 51 (baseado nas competições do IEEE), devido ao fato de que este é um número usualmente empregado para aferição de desempenho de meta-heurísticas, devido a fatores como o de que os resultados apresentados pela meta-heurística são aleatórios, sendo portanto necessário certa quantidade de simulações para a obtenção de padrões de eficácia dos algoritmos (JERONYMO, 2011).

Como o número de variáveis neste caso muda muito dependendo do caso de teste executado e do número de dispositivos a serem alocados simultaneamente, o tamanho da população é agora alterado de acordo com o número de variáveis de otimização. Para se ter valores de referência, é aplicada a mesma regra usualmente aplicada ao GA, de uma população dez vezes maior que o número de variáveis, para todos os algoritmos.

A precisão adotada como critério de parada também é variável de acordo com o sistema executado, tendo sido adotado o valor de 0.1% da perda do sistema original.

Os sistemas teste considerados nessas avaliações são o sistema de 14 barras com um e três patamares e o de 118 barras com um patamar de carga.

### 5.5.1. Tipos de comparação avaliados

Quatro tipos de comparação entre os algoritmos são considerados:

- Média dos resultados da função objetivo;
- Tempo médio de simulação;
- Média de gerações necessárias para convergência;
- Alocação mais frequente.

Para facilitar a coerência das comparações, foram utilizadas algumas normalizações: No caso da melhora da função objetivo, foi usado a melhora percentual em relação a perda original.

### 5.5.2. Sistema IEEE de 14 barras com um patamar de carga

Nesta seção são apresentados resultados de simulações utilizando o sistema teste de 14 barras considerando um único patamar de carga e a alocação simultânea de um dispositivo FACTS de cada tipo.

#### 5.5.2.1. Avaliação da alocação.

A tabela 5.3 apresenta os dois resultados mais frequentes de alocação para cada tipo de dispositivo e algoritmo utilizado. São exibidos os dois resultados mais frequentes, e as respectivas porcentagens de ocorrência.

Conforme se observa na tabela 5.3, o padrão de alocação dos dispositivos muda de forma considerável entre os algoritmos de busca no quesito de porcentagem de vezes em que determinados posicionamentos foram obtidos. Já no quesito do próprio posicionamento, estes foram similares com o padrão de barramento 3 e 7 mais frequentes para o STATCOM, linhas 1-5 e 2-4 para o dispositivo SSSC e linhas 1-5 e 2-4 para o UPFC.

Tabela 5.3: Alocação – Sistema de 14 barras 1 patamar

Algoritmo	STATCOM	SSSC	UPFC	% de ocorrência	% de melhor média
SSO	Barra 3	LT 2-4	LT 1-5	17.65	21.39
	Barra 3	Não alocado	LT 1-5	7.84	24.24
ORCS	Barra 7	LT 1-5	LT 2-4	5.88	20.25
	Barra 3	Não alocado	LT 1-5	5.88	16.55
GWO	Barra 3	Não alocado	LT 1-5	41.18	20.97
	Barra 3	LT 1-5	LT 2-4	9.80	24.28
GA	Barra 7	LT 1-5	LT 2-4	7.84	22.41
	Barra 3	LT 1-5	LT 2-4	5.88	22.54
DA	Barra 9	LT 2-4	LT 1-5	9.80	21.69
	Barra 7	LT 9-10	LT 1-5	3.92	16.45
CROW	Barra 3	LT 2-4	LT 1-5	35.29	20.02
	Barra 2	LT 2-4	LT 1-5	25.49	18.17

Fonte: O autor

De modo geral o algoritmo CROW apresentou melhor desempenho quanto a estabilidade da alocação uma vez que foi o único a obter mais de 60 % para a alocação quanto a soma dos percentuais dos seus dois resultados mais frequentes. Além do GWO, que da mesma forma obteve 50%, os outros algoritmos não chegaram perto dos 25%.

Esta maior probabilidade de oferecer os mesmos posicionamentos reflete apenas a capacidade do algoritmo de obter as mesmas alocações. Isso não significa que um algoritmo é melhor que outro apenas por este desempenho, pois existem diversos fatores que modificam o resultado encontrado, como a forma com que o algoritmo realiza o deslocamento por todo o espaço de busca evitando ótimos locais.


#### 5.5.2.2. Melhoria na função objetivo

A figura 5.8 apresenta a melhoria percentual média obtida por meio da alocação dos dispositivos FACTS providos pelos algoritmos de meta-heurística. Nos gráfico em



questão estão representados tanto a melhoria percentual da função objetivo, quanto os desvios padrão observados.

Figura 5.8: Melhoria percentual média e desvio padrão para 14 com 1 patamar, com um de cada dispositivo



Fonte: O autor

É possível notar duas fontes de informação, a média e o desvio padrão. Para uma comparação efetiva entre os algoritmos, não basta avaliar somente a média dos resultados, embora esta seja importante, mas também o desvio padrão, já que é possível mesmo com uma média considerada boa, verificar-se resultados variando muito entre si. Portanto no quesito de avaliar as médias obtidas, é notável a disparidade entre alguns algoritmos.


Neste caso, os únicos algoritmos que tiveram resultados melhores que o GA, foram o GWO e o SSO, sendo que o CROW e o ORCS apresentaram resultados similares. Já o DA, obteve o pior resultado, próximo a 16%, enquanto o GA teve próximo a 20% e o GWO e o SSO próximo aos 22% .

Quanto ao desvio padrão, comparativamente com o GA, todos exceto o DA tiveram um desvio padrão menor, sendo que o CROW e ORCS tiveram menos de 3 % de desvio.

Porém, como demonstrado no gráfico na figura 5.8, os que tiveram um menor desvio, não foram os que tiveram a maior média. Entretanto, o fato de que não se tem grande diferença (em torno de 0.3%) entre os desvio efetivamente entre CROW, SSO, ORCS e GWO, permite indicar que a comparação da melhora neste caso mostra-se suficiente. Assim, verifica-se um equilíbrio na comparação entre o SSO e o GWO, pois ambos apresentam média e desvio padrão próximos, já que, matematicamente a diferença foi de 0.02 % na média e 0.1 no desvio.

A figura 5.9 apresenta o efeito dos algoritmos sobre o caso 14 barras com um patamar, mostrando, no entanto, apenas o melhor resultado obtido e a média dos cinco melhores resultados.

Figura 5.9: Perdas obtidas pelos algoritmos (em pu).



(1)SSO (2)ORCS (3)GWO (4)GA (5)DA (6)CROW

Fonte: O autor

Tabela 5.4: Melhor alocação – Sistema de 14 barras 1 patamar


Algoritmo	STATCOM	SSSC	UPFC	Perdas em PU
SSO	4	LT 9-10	LT 1-5	0,1172
ORCS	7	LT 1-5	LT 2-4	0,1214
GWO	3	LT 2-4	LT 1-5	0,1184
GA	3	LT 1-5	LT 9-10	0,1163
DA	9	LT 2-4	LT 1-5	0,1220
CROW	3	LT 2-4	LT 1-5	0,1243

Fonte: O autor

### 5.5.2.3. Número Médio de gerações utilizadas

Outra forma de equiparar as meta-heurísticas estudadas é por meio de sua velocidade de convergência, que representa a rapidez de convergência do algoritmo em termos do número de gerações necessárias.

Figura 5.10: Número médio de gerações e desvio padrão



(1)SSO (2)ORCS (3)GWO (4)GA (5)DA (6)CROW

Fonte: O autor


A figura 5.10, representa o quantidade de gerações utilizadas para que o resultado fosse encontrado, ou seja representa a velocidade de convergência. Pode-se observar que todos os algoritmos, exceto o SSO, apresentaram melhor desempenho quando comparados ao GA, obtendo-se ao menos uma diferença de 30 gerações. O GWO e CROW obtiveram em média resultado com menos de 20 gerações, o que chega a ser um terço ou menos que o usado com o GA. Observa-se ainda pelo gráfico da figura 5.10 que o GWO foi o que convergiu com menor número de gerações. Além disso, observa-se que tanto o GA quanto o GWO, tiveram os menores desvios padrão, sendo assim uma taxa de convergência mais regular.

Assim, considerando ambos os quesitos, o algoritmo que apresenta o melhor desempenho é o GWO, pois possui baixo desvio padrão e baixo número de gerações.

#### 5.5.2.4. Tempo de simulação

Considerando que o sistema teste e a capacidade computacional utilizada em todas as simulações é idêntica, utiliza-se o tempo médio dentre as 51 simulações de cada caso como relevante figura de mérito para avaliação do desempenho dos algoritmos. Assim, como o demonstrado na figura 5.11, existe uma divergência bem acentuada em relação ao tempo necessário para convergência dos diferentes algoritmos.

Figura 5.11: Desvio e tempo médio para 14 um patamar em segundos



Fonte: O autor

Neste caso, os algoritmos SSO e DA tiveram desempenho pior em comparação ao GA. No entanto, mesmos para os algoritmos GWO, ORCS e CROW, existem divergências, sendo que o algoritmo GWO foi o que apresentou o melhor desempenho.

No entanto a comparação seria falha sem se observar o desvio padrão para a mesma, onde os desvios de todos, exceto os verificados para o ORCS e o GWO, se comportam de forma similar a média. Entretanto o que possui o menor desvio é o ORCS e o segundo melhor o GWO.

Considerando ambos os requisitos, o algoritmo GWO demonstrou melhor desempenho para este caso, pois possui comparativamente a menor média, com um desvio também baixo.

### 5.5.3. Sistema IEEE de 14 barras com três patamares de carga

Nesta seção são apresentados resultados de simulações utilizando o sistema teste de 14 barras, agora com três patamares de carga. Para definição dos patamares foi considerada a seguinte distribuição:

- Carga Pesada = 130% da carga Nominal;
- Carga leve = 50% da carga Nominal.

A permanência diária da carga Pesada foi considerada como sendo 10% do período, ou seja 2,4h enquanto a da Carga Leve de 30% do período, ou seja, 7.2h

#### 5.5.3.1. Alocação

A tabela 5.5 apresenta os resultados mais frequentes de alocação para cada tipo de dispositivo e cada algoritmo utilizado. São exibidos os dois resultados mais frequentes, com sua porcentagem de ocorrência, levando-se em conta todos os posicionamentos possíveis.

Conforme demonstrado, o padrão de alocação dos dispositivos muda de forma considerável entre os algoritmos de busca no quesito de porcentagem de vezes em que determinados posicionamentos foram obtidos. Já no quesito do próprio posicionamento, estes foram similares com o padrão de barramento 3 e 7 mais frequentes, para o dispositivo SSSC, não teve muito posicionamento nestes mais frequentes e para o UPFC linhas 1-5 e 2-4, lembrando que não existe alocação simultânea de UPFC e SSSC para a mesma linha.

Tabela 5.5: Alocação – Sistema de 14 barras com 3 patamares de carga


Algoritmo	STATCOM	SSSC	UPFC	% de ocorrência	% de melhor média
SSO	Barra 7	Não alocado	LT 1-5	11.76	15.58
	Barra 4	Não alocado	LT 2-4	9.80	20.83
ORCS	Barra 5	Não alocado	LT 1-5	7.84	7.64
	Barra 7	LT 1-5	Não alocado	5.88	8.55
GWO	Barra 3	Não alocado	LT 1-5	64.7	21.24
	Barra 4	Não alocado	LT 1-5	5.88	20.40
GA	Barra 3	Não alocado	LT 1-5	25.49	21.57
	Barra 8	LT 1-5	LT 2-4	3.92	24.23
DA	Barra 9	Não alocado	LT 1-5	11.76	18.35
	Barra 7	Não alocado	LT 1-5	9.80	17.04
CROW	Barra 3	LT 2-4	LT 1-5	49.02	18.34
	Barra 2	LT 2-4	LT 1-5	21.56	17.15

Fonte: O autor

#### 5.5.3.2. Melhoria da função objetivo

O gráfico representado na figura 5.12 representa a melhoria percentual média obtida por meio da alocação dos dispositivos FACTS providos pelos algoritmos de meta-heurística. Nos gráfico em questão estão representados tanto as melhoria percentuais quanto os desvios padrão observados em cada algoritmo.

Figura 5.12: Melhora percentual média e desvio padrão para o sistema de 14 barras com 3 patamares de carga



Fonte: O autor

Na avaliação das médias obtidas, nota-se a disparidade entre alguns algoritmos. Neste caso, o único que apresentou melhor resultado que o GA, foi o GWO e o pior entre os seis foi o ORCS, com um resultado próximo ao 7,5% enquanto o GA esteve próximo ao 17,5% e o GWO próximo aos 20%.

Quanto ao desvio padrão, todos exceto o DA tiveram um desvio padrão menor que o GA, e os algoritmos que comportaram-se melhor neste quesito foram o CROW, ORCS e GWO, tendo um desvio padrão de menos de 5 %.

Correlacionando os resultados, é considerável que existe quase um empate entre os algoritmos GWO e CROW, onde o primeiro obteve uma melhora mais efetiva, mas um desvio padrão maior se comparados com o segundo. Portanto se comparados com o GA, em termos do desempenho de melhoria percentual, tanto o CROW quanto o GWO mostram-se melhores.



Assim, a figura 5.13 apresenta o efeito dos algoritmos sobre o caso 14 barras com três patamares, mostrando, no entanto, apenas o melhor resultado obtido e a média dos cinco melhores resultados.

Figura 5.13: Perdas obtidas pelos algoritmos (em pu).




Tabela 5.6: Melhor alocação – Sistema de 14 barras 3 patamares


Algoritmo	STATCOM	SSSC	UPFC	Perdas em PU
SSO	4	LT 2-4	LT 1-5	0,1034
ORCS	7	Sem alocação	LT 1-5	0,1101
GWO	3	LT 2-4	LT 1-5	0,1006
GA	3	LT 2-4	LT 1-5	0,1008
DA	8	LT 1-5	LT 2-4	0,1069
CROW	3	LT 2-4	LT 1-5	0,1067

Fonte: O autor

### 5.5.3.3. Número médio de gerações

A figura 5.14, representa quantas gerações foram utilizadas para que o resultado fosse encontrado, ou seja representa a velocidade de convergência.

Figura 5.14: Média e desvio padrão de gerações utilizadas 14 barras 3 patamares



Fonte: O autor

Em se tratando de comparação com o GA, todos os algoritmos se saíram melhor que este, obtendo-se ao menos uma diferença de 15 gerações com o pior após o GA, o SSO. Entretanto o que se procura é entre todos os seis e não somente com o GA. Portanto, comparando todos estes, observa-se pelo gráfico da figura 5.12 que o GWO, fez-se do menor uso de gerações. Três dos algoritmos obtiveram seus resultados com quase o mesmo número de gerações. O GWO, ORCS e CROW, obtiveram todos em média resultado com menos de 20 gerações, o que chega a ser um terço ou menos que o usado com o GA.

Quanto ao desvio padrão observado, tanto o GA quanto o GWO, tiveram os menores desvios, sendo assim as menores irregularidades.

Assim, considerando ambos os quesitos, os algoritmos que apresentaram os melhores desempenho computacional são o GWO e o CROW, visto que possuem valores médios similares.


#### 5.5.3.4. Tempo de simulação

Como demonstrado na figura 5.15, existe uma divergência bem acentuada no tempo necessário para convergência dos diversos algoritmos.

Neste caso tendo como base o GA os algoritmos SSO e DA tiveram desempenhos piores. Os algoritmos GWO, ORCS e CROW apresentaram divergências quanto ao tempo utilizado, porém mesmo que estes sejam melhores que os obtidos pelo GA, o que teve o melhor desempenho geral quanto ao tempo de simulação foi o GWO.

O comportamento quanto ao desvio padrão foi de certa forma similar ao da média de tempo, onde o GWO também obteve o melhor desempenho.

Figura 5.15: desvio e tempo médio para 14 barras 3 patamares em segundos.



Fonte: O autor

#### 5.5.4. Sistema IEEE de 118 barras

Nesta seção são apresentados resultados de simulações utilizando o sistema teste de 118 barras considerando um único patamar de carga e a alocação simultânea de dois dispositivos FACTS de cada tipo.

##### 5.5.4.1. Alocação.

Conforme demonstrado na tabela 5.7, por não ter ocorrido correlação de frequência, esta tabela mostra o padrão de posicionamento e suas probabilidades de forma individual, ou seja mostra em relação a todos os resultados, quais foram os mais frequentes para cada tipo de dispositivo FACTS, sendo assim uma informação do STATCOM, não tem correlação com o SSSC, somente consigo mesmo,

Tendo em vista isto, a tabela 5.7 demonstra que os resultados obtidos mudam muito, com alguns poucos tendo seus dois dispositivos do mesmo tipo convergindo para uma mesma alocação.

Tabela 5.7: Alocação – Sistema de 118 barras.


Algoritmo	STATCOM (barra)		SSSC (LT)		UPFC (LT)	
SSO	13 (6.45%)	17 (6.45%)	42-49 (19.35%)	49-66 (19.35%)	61-62 (9.68%)	34-36 (19.35%)
	43 (6.45%)	37 (6.45%)	26-30 (6.45%)	42-49 (9.68%)	49-66 (9.68%)	61-62 (9.68%)
ORCS	45 (9.68%)	22 (9.68%)	49-66 (12.90%)	42-49 (19.35%)	34-36 (12.90%)	31-32 (9.68%)
	13 (6.45%)	44 (9.68%)	42-49 (6.45%)	49-66 (9.68%)	23-24 (6.45%)	34-36 (9.68%)
GWO	9 (6.45%)	21 (6.45%)	26-30 (19.35%)	89-92 (22.58%)	61-62 (16.13%)	31-32 (9.68%)
	45 (6.45%)	38 (6.45%)	89-92 (19.35%)	4-5 (12.90%)	5-6 (12.90%)	34-36 (9.68%)
GA	30 (12.90%)	95 (19.35%)	42-49 (25.80%)	77-80 (16.13%)	34-36 (12.90%)	34-36 (22.58%)
	22 (9.68%)	38 (6.45%)	89-90 (9.68%)	42-49 (9.68%)	61-62 (9.68%)	59-60 (9.68%)
DA	17 (9.68%)	93 (9.68%)	42-49 (22.58%)	49-66 (22.58%)	65-68 (12.90%)	3-5 (12.90%)
	30 (6.45%)	41 (6.45%)	4-5 (9.68%)	42-49 (16.13%)	5-6 (6.45%)	61-62 (12.90%)
CROW	38 (12.90%)	45 (16.13%)	42-49 (29.03%)	42-49 (25.80%)	65-68 (16.13%)	61-62 (12.90%)
	37 (9.68%)	16 (9.68%)	80-97 (9.68%)	19-20 (6.45%)	61-62 (9.68%)	23-24 (9.68%)

Fonte: O autor

#### 5.5.4.2. Melhoria da função objetivo

O gráfico representado na figura 5.16 que apresenta a melhoria percentual média obtida por meio da alocação dos dispositivos FACTS providos pelos algoritmos de meta-heurística. Nos gráfico em questão estão representados tanto a melhoria quanto o desvio padrão de cada um, representando assim o total das simulações realizadas de modo amostrado.

Figura 5.16: melhoria percentual média para o sistema de 118 barras com dois FACTS simultâneos de cada tipo




Fonte: O autor

Observa-se a disparidade entre todos os algoritmos com relação à média do GA. Entretanto o algoritmo com o melhor desempenho além do GA foi o GWO, visto que este obteve um resultado consideravelmente superior aos outros algoritmos, que apresentaram resultados médios similares entre si.

Assim, a figura 5.17 apresenta o efeito dos algoritmos sobre o caso 118 barras, mostrando, no entanto, apenas o melhor resultado obtido e a média dos cinco melhores resultados.

Figura 5.17: Perdas obtidas pelos algoritmos (em pu).



(1)SSO (2)ORCS (3)GWO (4)GA (5)DA (6)CROW

Fonte: O autor

Tabela 5.8: Melhor alocação – Sistema de 118 barras


Algoritmo	STATCOM		SSSC		UPFC		Perdas em PU
SSO	34	42	LT 54-59	LT 24-72	LT 5-6	LT 13-15	1,1715
ORCS	45	57	LT 70-75	LT 78-79	LT 54-59	LT 63-64	1,2225
GWO	32	51	LT 4-5	LT 1-3	LT 12-16	LT 54-59	1,1955
GA	23	51	LT 4-5	Sem alocação	LT 78-79	LT 1-3	1,1522
DA	19	47	LT 54-59	LT 78-79	LT 8-9	LT 70-71	1,2264
CROW	23	34	LT 54-59	LT 54-56	LT 4-5	LT 26-25	1,2286

Fonte: O autor

#### 5.5.4.3. Número médio de gerações

O gráfico da figura 5.18 representa o número gerações utilizadas para que a solução de alocação fosse encontrada.

Figura 5.18: média de gerações utilizadas 118 e desvio



Fonte: O autor

Em se tratando de comparação com o GA, todos os algoritmos se saíram melhor que este, obtendo-se ao menos uma diferença de 10 gerações. Observa-se pelo gráfico da figura 5.18 que o algoritmo ORCS foi o que convergiu com o menor número de gerações para convergência.

Com relação ao desvio padrão, tanto o GA quanto o DA e o ORCS, tiveram os menores desvios, sendo assim as menores irregularidades.


Assim, os melhores algoritmos considerando ambos os quesitos são o DA e o ORCS, visto que possuem número médio similares



#### 5.5.4.4. Tempo de simulação

Como demonstrado na figura 5.19, existe uma divergência bem acentuada no tempo necessário para a convergência de cada algoritmo.

Figura 5.19: desvio e tempo médio para 118 em segundos.



Fonte: O autor

Neste caso, o algoritmo DA obteve o pior desempenho. Quanto aos demais, mesmo havendo divergências, o que apresentou melhor desempenho foi o algoritmo ORCS, que também apresentou o menor desvio padrão.

#### 5.5.4.5. Considerações quanto ao tempo de simulação

Esta seção corresponde à compilação de dados pertinentes, comparáveis, à respeito tanto das simulações realizadas e demonstradas neste capítulo quanto as demonstradas no Apêndice.


Sendo assim, o gráfico da figura 5.20 apresenta o comportamento que permite comparar a relação entre o tempo médio de simulação de cada algoritmo para cada um dos casos estudados, ou seja, o sistema de 14 barras com 1 patamar de carga, o sistema de 30 barras e o sistema de 57 barras, ambos considerando um controlador FACTS de cada tipo; e o sistema de 118 barras com 1 patamar de carga considerando a alocação simultânea de 2 controladores FACTS de cada tipo, ou seja apresentados todos os casos estudados exceto o 14 barras três patamares, já que este leva em conta aspectos operacionais que amplificam a complexidade do problema

É possível observar que, no que diz respeito ao aumento de complexidade envolvida, o aumento do tempo para os algoritmos CROW, ORCS e GWO é de ordem inferior ao do requerido para os algoritmos GA, DA e SSO, visto que seus gráficos apresentam disparidades na taxa de crescimento do consumo de tempo, sendo portanto mais efetivos para tratamento de sistemas de maior porte.

Utilizando-se dos mesmos casos de estudo demonstrados na figura 5.20, a figura 5.21 corresponde à comparação da dificuldade da convergência, ou seja o número de gerações necessário para que o algoritmo encontre um resultado. Sendo assim em relações a esta forma de comparação, é visível que embora a complexidade dos casos estudados sejam diferentes entre si, este número de gerações necessárias para a convergência não sofreu muita mudança, e em comparação com o GA, o único com dificuldade similar foi o algoritmo SSO, enquanto os demais apresentaram sempre um número de gerações pelo menos 50% inferior.


Parte desta redução pode ser explicada por alguma inaptidão dos algoritmos de escapar de ótimos locais, onde o algoritmo converge para um destes, mas não possui a capacidade de buscar outros ótimos locais melhores. Tal capacidade ajuda na possível obtenção de resultados melhores, visto que a natureza da alocação implica na existência de inúmeros ótimos locais. Porém, observa-se que em várias das simulações com os diferentes métodos, mesmo com a redução da quantidade de gerações utilizadas, encontraram-se resultados melhores do que os obtidos com o GA, base das comparações.

Figura 5.20: tempo médio em segundos utilizado para cada caso de estudo



Fonte: O autor

Figura 5.21: Número médio de gerações utilizada para cada caso de estudo



Fonte: O autor

#### 5.5.4.6. Considerações quanto a influência dos Controladores nos casos teste simulados

A tabela 5.9 trata de apresentar a influencia da presença dos compensadores FACTS considerados no presente trabalho, indicando o resultado comparativo de seus efeitos de controle sobre as diferentes redes elétricas em que a alocação foi aplicada.

Embora os resultados sejam relacionados apenas à redução das perdas ativas, esta tabela busca quantificar esse efeito para cada caso estudado, indicando os ganhos obtidos através do percentual de redução de geração e também o nível de carga aliviada do sistema, além da expectativa de economia de energia ao longo de um ano, ressaltando a relevância da participação dos Controladores FACTS na melhoria da eficiência operativa do sistema elétrico.

Tabela 5.9:

<b>caso</b>	<b>Carga sistema (MW)</b>	<b>Geração sem FACTS (MW)</b>	<b>Geração com FACTS (MW)</b>	<b>Redução das perdas (MW)</b>	<b>% de diminuição da geração</b>	<b>Carga similar à redução obtida</b>	<b>Acumulado ano (GWh)</b>
<b>14-1</b>	259.00	274.91	271.01	3.90	1.42	barra 11	34.32
<b>14-3</b>	227.90	241.37	238.38	2.99	1.24	barra 11	26.19
<b>30</b>	189.20	191.73	190.80	0.93	0.49	barra 24	8.15
<b>57</b>	1250.80	1280.50	1276.07	4.43	0.35	barra 54	38.81
<b>118</b>	4242.00	4375.96	4361.88	14.08	0.32	barra 21	123.37

Fonte: O autor

## 6. Conclusão

Neste trabalho foi apresentada uma metodologia para avaliação de diferentes técnicas meta-heurísticas para a alocação de Controladores FACTS de Segunda Geração em sistemas de transmissão de energia elétrica.

Considerando suas diferentes possibilidades de controle, foram empregados no processo de alocação os três principais controladores da segunda geração: o STATCOM (*Static VAR Compensator*), o SSSC (*Static Synchronous Series Converter*) e o mais avançado destes, o UPFC (*Unified Power Flow Controller*). Foram apresentadas suas características construtivas e seus princípios de operação, destacando os aspectos comuns dessa segunda geração, que tem como base a atuação de conversores eletrônicos avançados proporcionando compensadores que atuam como fontes de tensão eletronicamente controladas. Para tanto foi implementada uma rotina para cálculo do fluxo de potência que incorpora a representação destes controladores, permitindo a avaliação de seus efeitos em diversos arranjos com a rede de transmissão.

Tendo em vista a complexidade e a escala dos problemas que tratam da determinação de pontos da rede elétrica mais efetivos para alocação de controladores considerando suas diferentes funcionalidades, foram avaliados cinco diferentes técnicas meta-heurísticas, além da já consagrada técnica de Algoritmos Genéticos (AG): Algoritmo Crow (CROW), *Dragonfly Algorithm* (DA), *Grey Wolf Optimizer* (GWO), *One Rank Cuckoo Search* (ORCS) e *Social-Spider Optimization* (SSO). Essas técnicas baseiam-se em estratégias de evolução populacional orientadas pela melhoria de um objetivo especificado. Foram apresentadas as características que definem o processo de melhoria da solução de cada técnica, destacando-se também a quantidade e complexidade dos parâmetros de ajuste associados.

A metodologia apresentada, a partir da combinação de cada técnica meta-heurística com a rotina de cálculo de fluxo de potência desenvolvida permitiu a avaliação da efetividade do processo de busca, bem como da medição da eficiência computacional das mesmas para a solução do problema de alocação dos controladores FACTS. Tendo como o objetivo a avaliação das meta-heurísticas empregadas, foram utilizados vários parâmetros de comparação: probabilidade de alocação, melhora média obtida, número médio de gerações e o tempo médio utilizado.

Considerando a melhora média obtida pelas diferentes meta-heurísticas avaliadas, o algoritmo GWO, foi o que obteve o melhor desempenho geral. Com relação ao tempo médio de simulação, em todos os casos teste simulados, os algoritmos CROW, GWO e ORCS convergiram em um tempo significativamente menor quando comparado ao GA. Em contraste, os algoritmos DA e SSO apresentaram tempos de convergência bem maiores que o GA.

No que diz respeito ao número de gerações necessárias para convergência, todos os algoritmos, com exceção do SSO, convergiram com no máximo 50% do número de gerações usado pelo GA para convergir. Mesmo que esta métrica possa ter influência cruzada com outros aspectos levantados, a grande diferença obtida, por si só, deve ser destacada.

Embora nem todas as métricas possam ser definitivas para avaliação da performance das diferentes técnicas, evidencia-se pelo estudo realizado, que o GWO foi o que apresentou, no conjunto, desempenhos melhores que o GA tanto em relação aos valores da função objetivo, quanto no tempo e na quantidade de gerações utilizadas, sendo portanto um algoritmo que demonstrou potencialidade para lidar com problemas complexos e apontar soluções adequadas para alocação de dispositivos FACTS.

### 6.1. Trabalhos futuros

Para os desenvolvimentos futuros, vislumbra-se a possibilidade de avaliar a utilização de funções multiobjetivo, visto que poderiam em uma mesma simulação, atender diferentes requisitos da rede elétrica, tais como melhoria do perfil de tensão e fluxo de reativos, assim como envolver aspectos econômicos, avaliando o custo-benefício da instalação de Controladores FACTS.

Além disso, a proposição de um método de otimização híbrido, aproveitando-se as características mais eficientes dos métodos estudados, poderia ser investigada.

## Bibliografia

ACHA, E.; KAZEMTABRIZI, B.: A New STATCOM Model for Power Flows Using the Newton–Raphson Method. *IEEE Transactions on Power Systems*, v. 28, n. 3, p. 2455–2465, 2013.

ACHARJEE, P.: Optimal Power Flow with UPFC Using Self- Adaptive Differential Evolutionary Technique under Security Constraints. *International Conference on Recent Developments in Control, Automation and Power Engineering*, p. 177–182, 2015.

ACHARYA, Naresh; YOME, A.S.; MITHULANANTHAN, Nadarajah. Facts about Flexible AC Transmission Systems ( FACTS ) Controllers : Practical Installations and Benefits. *European Transactions on Electrical Power*, 2004.

ALHASAWI, F. B.; ALABDULJABBAR, A. A.: Economic Viability of Application of FACTS Devices for Reducing Generating Costs. *Power and Energy Society General Meeting*, p. 1–8, 2010.

ANEEL.: *Relatório de fiscalização 2010-SFE.* , 2010.

BANU, R. N.; DEVARAJ, D.: Genetic Algorithm Approach for Optimal Power Flow with FACTS devices. *4th International IEEE Conference Intelligent Systems*, n. 3, p. 11–16, 2008.

BIYANTO, T. R.; Afdanny, N.; Alfarisi, M.; Haksoro, T.; Kusumaningtyas, S. A.: Optimization of Acid Gas Sweetening Plant Based on Least Squares - Support Vector Machine (LS-SVM) Model and Grey Wolf Optimizer (GWO). *International Seminar on Sensors, Instrumentation, Measurement and Metrology*, p. 1–7, 2016.

CARVALHO, A. P. L. F.: *Algoritmos Genéticos Características Gerais dos AGs*. Disponível em: <<http://conteudo.icmc.usp.br/pessoas/andre/research/genetic/>>. Acesso em: 12 maio 2017.

COELHO, L. S. ; Richter, C.; Mariani, V. C.; Askarzadeh, A.: Modified Crow Search Approach Applied to Electromagnetic Optimization. *IEEE Conference on Electromagnetic Field Computation*, v. 59, n. 2, p. 2013, 2016.

- DAELY, P. T.; SHIN, S. Y.: Range Based Wireless Node Localization Using Dragonfly Algorithm. *International Conference on Ubiquitous and Future Networks*, p. 1012–1015, 2016.
- DAS, K. R.; DAS, D.; DAS, J.: Optimal Tuning of PID Controller using GWO Algorithm for Speed Control in DC motor. *International Conference on Soft Computing Techniques and Implementations*, p. 108–112, 2015.
- DEB, T.; SIDDIQUI, A. S.; IQBAL, F.: Optimal location of FACTS device using Meta Heuristic Search Algorithm. *India Conference*, p. 1–4, 2015.
- DETORAKIS, Z.; TAMBOURATZIS, G.: Introduction of a Sectioned Genetic Algorithm for Large Scale Problems. *Bio-Inspired Models of Network, Information and Computing Systems*, 2007.
- EL-FERGANY, A. A.; EL-HAMEED, M. A.: Efficient frequency controllers for autonomous two-area hybrid microgrid system using social-spider optimiser. *IET Generation, Transmission & Distribution Special*, v. 11, p. 637–648, 2017.
- FERREIRA, L E. B.: *O papel institucional da CCEE e a operação do mercado de energia*. Disponível em: <<https://pt.slideshare.net/CCEEOficial/o-papel-institucional-da-ccee-e-a-operao-do-mercado-de-energia>>. Acesso em: 6 jun. 2017.
- FUERTE-ESQUIVEL, C. R.; ACHA, E.; AMBRIZ-PÉREZ, H. A.: Comprehensive Newton-Raphson UPFC Model for the Quadratic Power Flow Solution of Practical Power Networks. *IEEE Transactions on Power Systems*, v. 15, n. 1, p. 102–109, 2000.
- GERBEX, S.; CHERKAoui, R.; GERMOND, A. J. :Optimal Location of FACTS Devices to Enhance Power System Security. *PowerTech Conference Proceedings*, 2003.
- GERBEX, S.; CHERKAoui, R.; GERMOND, A. J.: Optimal Location of Multi-Type FACTS Devices in a Power System by Means of Genetic Algorithms. *IEEE Power Engineering Society International Conference on Power Industry Computer Applications*, v. 16, n. 3, p. 537–544, 2001.
- JERONYMO, D.C.: Metaheurísticas Aplicadas ao Problema de Despacho Econômico de Energia Elétrica. Dissertação de Mestrado, DELT-UFPR, 2011.



KAMEL, S.; ABDEL-AKHER, M.; EL-NEMR, M. K.: Implementation of SSSC Model in the Newton- Raphson Power Flow Formulation Using Current Injections. *Universities Power Engineering Conference*, 2010.

KLEIN, C.; Segundo, E. H. V.; Mariani, V. C.; Coelho, L. S.: Modified Social-Spider Optimization Algorithm Applied to Electromagnetic Optimization. *IEEE Transactions on Magnetics*, v. 52, n. 3, p. 28–31, 2016.

LUZIA, L. F.; RODRIGUES, M. C.: *Introdução ao Escalonamento e Aplicações Estudo sobre as Metaheurísticas Índice*. Disponível em:  
<<https://www.ime.usp.br/~gold/cursos/2009/mac5758/LeandroMauricioHeuristica.pdf>>. Acesso em: 29 abr. 2017.

MALAKAR, T.; Sinha, N.; Goswami, S. K.; Saikia, L. C.: Optimal Location and Size Determination of FACTS Devices by Using Multiobjective Optimal Power Flow. *TENCON*, p. 474–478, 2010.

MAROUANI, I.; Guesmi, T.; Hadj, A. H.; Ouali, A.: Optimal Location of Multi Type FACTS Devices for Multiple Contingencies using Genetic Algorithms. *8th International Multi-Conference on Systems, Signals and Devices*, 2011.

MINAS E ENERGIA, Ministerio.: *Ranking Mundial de Energia e Ranking de Indicadores de Uma Variável*. Disponível em:  
<<http://www.mme.gov.br/documents/10584/1139093/Ranking+Mundial+de+Energia+2015.pdf/f088fe16-e0d2-49ad-b72c-8376f749c661>>. Acesso em: 27 abr. 2017.

MIRJALILI, S.: Dragonfly Algorithm: A New Meta-Heuristic Optimization Technique for Solving Single-Objective, Discrete, and Multi-Objective Problems. *Neural Computing and Applications*, v. 27, n. 4, p. 1053–1073, 2015.

NETO, L. B.; Becceneri, J. C.; Silva, J. D. S.; Luz, E. F. P.; Neto, A. J. S.: *Fundamentos de Otimização e Inteligência Artificial*, 2009.

PADIYAR, K.R.: *FACTS Controllres in Power Transmission and Distribution*. [S.l.]: New Age International Publishers, 2007.

PARASTAR, A.; PIRAYESH, A.; NIKOUKAR, J.: Optimal Location of FACTS Devices in a Power System Using Modified Particle Swarm Optimization. *UPEC*, p. 1122–1128, 2007.

PATERNI, P.; VITET, S.; BENA, M.: Optimal Location of Phase Shifters in the French Network by Genetic Algorithm. *IEEE Transactions on Power Systems*, v. 14, n. 1, p. 37–42, 1999.

PEREIRA, L. A. M.; Rodrigues, D.; Ribeiro, P. B.; Papa, J. P.: Social-Spider Optimization-Based Artificial Neural Networks Training and its Applications for Parkinson's Disease Identification. *IEEE 27th International Symposium on Computer-Based Medical Systems*, p. 14–17, 2014.

RAJPUT, S.; Parashar, M.; Dubey, H. M.; Pandit, M.: Optimization of benchmark functions and practical problems using Crow Search Algorithm. *International Conference on Eco-friendly Computing and Communication Systems*, 2016.

SALAM, M. A.; Zawbaa, H. M.; Emary, E. Ghany, K. K. A.; Parv, B.: A hybrid dragonfly algorithm with extreme learning machine for prediction. *INnovations in Intelligent SysTems and Applications*, 2016.

SARAVANAN, M; Slochanal, S. Mary. Raja.; Venkatesh, P; Abraham, J. P. S.: Application of PSO technique for optimal location of FACTS Devices Considering System Loadability and cost of Installation. *Power engineering Conference*, 2005.

SETH, J. K.; CHANDRA, S.: Intrusion Detection Based on Key Feature Selection using Binary GWO. *Computing for Sustainable Global Development (INDIACom)*, p. 3735–3740, 2016.

SINGH, S. N.; DAVID, A. K.: Placement of FACTS Devices in Open Power Market. *Proceedings of the 5th International Conference on Advances in Power System Control, Operation and Management*, n. October, p. 173–177, 2000.

TIWARI, R.; NIAZI, K. R.; GUPTA, V.: Optimal Location of FACTS Devices for Improving Performance of the Power Systems. *Power and Energy Society General Meeting*, p. 1–8, 2012.

TORTELLI, O L; SANTOS, A.: Functional Strategy for Allocating FACTS Controllers O. *CIGRÉ INTERNATIONAL SYMPOSIUM*, 2011.

TORTELLI, O. L.: Alocação e Operação de Controladores FACTS em Sistemas Elétricos de Potência. *Tese de Doutorado, FEEC-UNICAMP*, 2010.

WASHINGTON, University: *Power Systems Test Case Archive*. Disponível em: <<http://www2.ee.washington.edu/research/pstca/>>. Acesso em: 4 fev. 2017.

William, F. T.; HART, C. :Power Flow Solution by Newton's Method. n. 11, 1967.

YANG, Z.; Shen, C.; Crow, M. L.; Zhang, L.: An Improved STATCOM Model for Power Flow Analysis. *Power Engineering Society Summer Meeting*, p. 1121–1126, 2000.

ZAWBAA, H. M.; Emary, E.; Hassanien, A. E.; Parv, B.: A wrapper approach for feature selection based on swarm optimization algorithm inspired from the behavior of social-spiders. *Soft Computing and Pattern Recognition*, p. 25–30, 2015.

ZHANG, X. P.: Advanced Modeling of the Multicontrol Functional Static Synchronous Series Compensator ( SSSC ) in Newton Power Flow. *IEEE Transactions on Power Systems*, v. 18, n. 4, p. 1410–1416, 2003.

## Apêndice

Nesta seção suplementar, são apresentados os resultados de simulações realizadas, com os sistemas teste de 30 barras e 57 barras do IEEE, visando ampliar a avaliação do comportamento dos algoritmos para frente a diferentes complexidades.

### A.1. Sistema teste 30 barras

Nesta seção são apresentados resultados de simulações utilizando o sistema teste de 30 barras e a alocação simultânea de um dispositivo FACTS de cada tipo.

#### A.1.1. Avaliação da alocação.

A tabela A.1 apresenta os dois resultados mais frequentes de alocação para cada tipo de dispositivo e algoritmo utilizado. São exibidos os dois resultados mais frequentes, e as respectivas porcentagens de ocorrência.

Conforme se observa na tabela A.1, o padrão de alocação dos dispositivos muda de forma considerável entre os algoritmos de busca no quesito de porcentagem de vezes em que determinados posicionamentos foram obtidos. Já no quesito do próprio posicionamento, para o STATCOM, não houve um padrão quanto ao seu posicionamento, para o dispositivo SSSC, não houve um padrão pelo fato em que não ocorreu posicionamento para este, ou a alocação do UPFC sobre escreveu este posicionamento, já para o UPFC a alocação mais frequente foi a linha 2-4.

Tabela A.1: Alocação – Sistema de 30 barras

Algoritmo	STATCOM	SSSC	UPFC	% de ocorrência	% de melhor média
SSO	Barra 9	Não alocado	LT 2-4	6.45	32.73
	Barra 7	LT 2-4	Não alocado	3.22	34.9315
ORCS	Barra 2	Não alocado	LT 2-4	3.22	27.29
	Barra 5	LT 1-30	LT 2-4	3.22	26.33
GWO	Barra 1	Não alocado	LT 2-4	25.80	39.37
	Barra 20	Não alocado	LT 2-4	6.45	37.69
GA	Barra 7	Não alocado	LT 3-4	6.45	24.20
	Barra 20	LT 9-10	LT 3-4	3.22	27.30
DA	Barra 29	LT 8-28	LT 2-4	9.67	29.11
	Barra 1	Não alocado	LT 8-28	6.45	13.70
CROW	Barra 11	LT 6-9	LT 2-4	6.45	27.50
	Barra 12	LT 9-10	LT 2-4	6.45	21.14


Fonte: O autor

De modo geral o algoritmo GWO apresentou melhor desempenho quanto a estabilidade da alocação uma vez que foi o único a obter mais de 30 % para a alocação quanto a soma dos percentuais dos seus dois resultados mais frequentes. Sem ser o DA que da mesma forma obteve 16%, os outros algoritmos não chegaram perto dos 15% da mesma forma.

#### A.1.2. Melhoria na função objetivo

A figura A.1 apresenta a melhoria percentual média obtida por meio da alocação dos dispositivos FACTS providos pelos algoritmos de meta-heurística. Nos gráfico em questão estão representados tanto a melhoria percentual da função objetivo, quanto os desvios padrão observados.

Figura A.1: Melhoria percentual média e desvio padrão para 30 barras com um de cada dispositivo



Fonte: O autor

É possível notar duas fontes de informação, a média e o desvio padrão. Para uma comparação efetiva entre os algoritmos, não basta avaliar somente a média dos resultados, embora esta seja importante, mas também o desvio padrão, já que é possível mesmo com uma média considerada boa, verificar-se resultados variando muito entre si. Portanto no quesito de avaliar as médias obtidas, é notável a disparidade entre alguns algoritmos.


Neste caso, os únicos algoritmos que tiveram resultados melhores que o GA, foram o GWO e o SSO, sendo que o CROW e o ORCS apresentaram resultados próximos ao GA. Já o DA, obteve o pior resultado, próximo a 19%, enquanto o GA teve próximo a 27% e o GWO e o SSO próximo aos 35%.

Quanto ao desvio padrão, comparativamente com o GA que obteve desvio de 8,5% , todos exceto o DA tiveram um desvio padrão menor que 8%, sendo que o ORCS teve 5.4% de desvio.

Portanto nesta comparação é possível determinar que para o caso estudado de 30 barras o algoritmo GWO foi o obteve o melhor desempenho visto que este obteve a maior média de melhora com 36,92% de melhora, e obtendo desvio padrão similar aos outros algoritmo, porém inferior ao do GA.

Assim, a figura A.2 apresenta o efeito dos algoritmos sobre o caso 30 barras, mostrando, no entanto, apenas o melhor resultado obtido e a média dos cinco melhores resultados.

Figura A.2: Perdas obtidas pelos algoritmos (em pu).



Fonte: O autor

Tabela A.2: Melhor alocação – Sistema de 30 barras

Algoritmo	STATCOM	SSSC	UPFC	Perdas em PU
SSO	12	LT 12-15	LT 2-4	0,0142
ORCS	22	LT 2-4	LT 12-15	0,0161
GWO	28	LT 9-11	LT 2-4	0,0135
GA	22	LT 2-4	LT 24-25	0,0149
DA	24	Sem alocação	LT 2-4	0,0161
CROW	12	LT 9-11	LT 2-4	0,0172


Fonte: O autor

### A.1.3. Número Médio de gerações utilizadas

Outra forma de equiparar as meta-heurísticas estudadas é por meio de sua velocidade de convergência, que representa a rapidez de convergência do algoritmo em termos do número de gerações necessárias.



Figura A.3: Número médio de gerações e desvio padrão



(1)SSO (2)ORCS (3)GWO (4)GA (5)DA (6)CROW

Fonte: O autor

A figura A.3, representa o quantidade de gerações utilizadas para que o resultado fosse encontrado, ou seja representa a velocidade de convergência. Pode-se observar que todos os algoritmos, exceto o SSO, apresentaram melhor desempenho quando comparados ao GA, obtendo-se ao menos uma diferença de 30 gerações. O CROW obteve em média resultado com menos de 20 gerações, o que chega a ser um terço ou menos que o usado com o GA.


Considerando inclusive os desvios obtidos é possível afirmar que para este caso de estudo, o algoritmo CROW foi o que obteve o melhor desempenho em termos do número de gerações necessárias, e como houve muita diferença, em torno de 10 gerações para o segundo melhor, o GWO, não foi preciso considerar os desvios para se determinar o melhor neste caso.

#### A.1.4. Tempo de simulação

Considerando que o sistema teste e a capacidade computacional utilizada em todas as simulações é idêntica, utiliza-se o tempo médio dentre as simulações de cada caso como relevante figura de mérito para avaliação do desempenho dos algoritmos. Assim, como o demonstrado na figura A.4, existe uma divergência bem acentuada em relação ao tempo necessário para convergência dos diferentes algoritmos.

Neste caso, os algoritmos SSO e DA tiveram desempenho pior em comparação ao GA. No entanto, mesmo para os algoritmos GWO, ORCS e CROW, existem divergências, sendo que o algoritmo CROW foi o que apresentou o melhor desempenho.

Figura A.4: Desvio e tempo médio para 30 barras em segundos



Fonte: O autor

No entanto a comparação seria falha sem se observar o desvio padrão para a mesma, onde os desvios de todos, exceto o verificado para o ORCS, se comportam de forma similar a média. Entretanto o que possui o menor desvio é o ORCS e o segundo melhor o CROW.

Considerando ambos os requisitos, os algoritmos CROW e ORCS empatam pois embora a média do ORCS seja maior, seu desvio padrão é muito menor, ou seja embora a média do CROW seja menor, ocorrem muito mais variações em seu tempo.

## A.2. Sistema IEEE de 57 barras

Nesta seção são apresentados resultados de simulações utilizando o sistema teste de 57 barras.

### A.2.1. Alocação

Conforme demonstrado na tabela A.3, por não ter ocorrido correlação de frequência, esta tabela mostra o padrão de posicionamento e suas probabilidades de forma individual, ou seja mostra em relação a todos os resultados, quais foram os mais frequentes para os determinados aparelhos, sendo assim uma informação do STATCOM, não tem correlação com o SSSC, somente consigo mesmo,

Tendo isto em vista, a tabela A.3 demonstra que os resultados obtidos mudam muito, com alguns poucos tendo seus dois dispositivos do mesmo tipo convergindo para uma mesma alocação. Sendo assim em virtude dos resultados de posicionamento obtidos, não é possível definir um padrão de resultados muito definido.

Tabela A.3: Alocação – Sistema de 57 barras.


Algoritmo	STATCOM (barra)		SSSC (LT)		UPFC (LT)	
SSO	Barra 14	12.90%	LT 2-3	38.71%	LT 8-9	22.58%
	Barra 38	12.90%	LT 8-9	16.13%	LT 9-10	12.90%
ORCS	Barra 32	9.67%	LT 2-3	38.71%	LT 8-9	16.12%
	Barra 43	9.67%	LT 8-9	9.68%	LT 9-10	16.12%
GWO	Barra 32	32.25%	LT 8-9	48.39%	LT 8-9	22.58%
	Barra 25	22.58%	LT 2-3	6.45%	LT 2-3	6.45%
GA	Barra 32	19.34%	LT 8-9	25.81%	LT 13-15	19.35%
	Barra 14	12.90%	LT 2-3	19.35%	LT 37-39	12.90%
DA	Barra 12	16.13%	LT 2-3	16.12%	LT 8-9	19.35%
	Barra 29	9.67%	LT 12-17	12.90	LT 3-4	12.90%
CROW	Barra 38	16.13%	LT 9-10	9.68%	LT 8-9	32.26%
	Barra 23	6.45%	LT 12	9.68%	LT 9-10	29.03%

Fonte: O autor

### A.2.2. Melhoria da função objetivo

O gráfico representado na figura A.5 representa a melhoria percentual média obtida por meio da alocação dos dispositivos FACTS providos pelos algoritmos de meta-heurística. Nos gráfico em questão estão representados tanto as melhoria percentuais quanto os desvios padrão observados em cada algoritmo.

Figura A.5: Melhora percentual média e desvio padrão para o sistema de 57 barras



Fonte: O autor


Na avaliação das médias obtidas, nota-se a disparidade entre alguns algoritmos. Neste caso, o único que apresentou melhor resultado que o GA, foi o SSO e o pior entre os seis foi o CROW, com um resultado próximo ao 8% enquanto o GA esteve próximo ao 13,5% e o SSO próximo aos 15%.

Quanto ao desvio padrão, todos exceto o SSO tiveram um desvio padrão menor que o GA, e o algoritmo que comportou-se melhor neste quesito foi o DA, tendo um desvio padrão de menos de 3 %.

Correlacionando os resultados, é considerável que o SSO foi o que obteve o melhor desempenho e que existe quase um empate entre os algoritmos GWO e o GA, pois estes, apresentaram os melhores desempenhos seguidos do SSO, mas tanto em média de resultados quanto em desvio padrão, obtiveram resultados similares.

Assim, a figura A.6 apresenta o efeito dos algoritmos sobre o caso 57 barras com três patamares, mostrando, no entanto, apenas o melhor resultado obtido e a média dos cinco melhores resultados.

Figura A.6: Perdas obtidas pelos algoritmos (em pu).



Fonte: O autor

Tabela A.4: Melhor alocação – Sistema de 57 barras


Algoritmo	STATCOM	SSSC	UPFC	Perdas em PU
SSO	23	LT 3-4	LT 1-2	0.2229
ORCS	9	LT 3-4	LT 1-2	0.2309
GWO	41	LT 1-2	LT 3-4	0.2378
GA	3	LT 3-4	LT 1-2	0.2195
DA	50	LT 3-4	LT 41-43	0.2560
CROW	23	LT 1-15	LT 3-4	0.2531

Fonte: O autor

### A.2.3. Número médio de gerações

Figura A.7, representa quantas gerações foram utilizadas para que o resultado fosse encontrado, ou seja representa a velocidade de convergência.

Figura A.7: Média e desvio padrão de gerações utilizadas 57 barras



Fonte: O autor

Em se tratando de comparação com o GA, todos os algoritmos exceto o SSO, se saíram melhor que este, obtendo-se ao menos uma diferença de 30 gerações para o restante dos algoritmos. Entretanto o que se procura é entre todos os seis e não somente com o GA. Portanto, comparando todos estes, observa-se pelo gráfico da figura A.7 que o GWO, fez-se do menor uso de gerações. Três dos algoritmos obtiveram seus resultados com quase o mesmo número de gerações. O GWO, ORCS e CROW, obtiveram todos em média resultado com menos de 25 gerações, o que chega a ser menos da metade que o usado com o GA.

Quanto ao desvio padrão observado, tanto o GA quanto o ORCS e o DA, tiveram os menores desvios, sendo assim as menores irregularidades.

Assim, considerando ambos os quesitos, os algoritmos que apresentaram os melhores desempenho computacional são o ORCS e o DA, visto que possuem número médio similares.

#### A.2.4. Tempo de simulação


Como demonstrado na figura A.8, existe uma divergência bem acentuada no tempo necessário para convergência dos diversos algoritmos.

Neste caso tendo como base o GA os algoritmos SSO e DA tiveram desempenhos piores. Os algoritmos GWO, ORCS e CROW apresentaram pouca divergências quanto ao tempo utilizado, porém mesmo que estes sejam melhores que os obtidos pelo GA, o que teve o melhor desempenho geral quanto ao tempo de simulação foi o CROW.

Já em se tratando do desvio obtido, o único que obteve um desvio menor que o do GA foi o ORCS, sendo assim, é possível afirmar que embora a média de tempo do algoritmo CROW tenha sido menor, é similar ao do ORCS, e se em conjunto com o desvio, o algoritmo ORCS possui então um desempenho melhor que o CROW, devido ao seu baixo desvio, sendo assim neste caso de estudo no quesito de tempo utilizado o ORCS obteve um melhor desempenho.



Figura A.8: desvio e tempo médio para 57 barras em segundos.



Fonte: O autor